

燃料电池系统 建模与优化控制

张立炎 全书海 著

<http://www.phei.com.cn>



电子工业出版社
PUBLISHING HOUSE OF ELECTRONICS INDUSTRY

燃料电池系统建模与优化控制

张立炎 全书海 著

電子工業出版社·

Publishing House of Electronics Industry

北京·BEIJING

内 容 简 介

本书紧密结合当前质子交换膜燃料电池的研究热点,对质子交换膜燃料电池系统建模与优化控制的研究进行了较为详尽的分析和总结。全书共分为六章,主要内容包括绪论、质子交换膜燃料电池系统建模、质子交换膜燃料电池模拟仿真、质子交换膜燃料电池空气供应系统控制、质子交换膜燃料电池水管理、质子交换膜燃料电池系统控制。

本书可供从事电气、自动化、能源、环保、船舶、汽车领域的科技工作者和工程技术人员使用,也可供高等院校有关专业师生参考。

未经许可,不得以任何方式复制或抄袭本书之部分或全部内容。
版权所有,侵权必究。

图书在版编目(CIP)数据

燃料电池系统建模与优化控制 / 张立炎, 全书海著. —北京: 电子工业出版社, 2011. 11

ISBN 978-7-121-14637-4

I. ①燃… II. ①张… ②全… III. ①燃料电池—系统建模 ②燃料电池—系统最优化 IV. ①TM911.4

中国版本图书馆CIP数据核字(2011)第190600号

责任编辑: 董亚峰 特约编辑: 王 纲

印 刷:

装 订:

出版发行: 电子工业出版社

北京市海淀区万寿路173信箱 邮编 100036

开 本: 850×1 168 1/32 印张: 7.875 字数: 252千字

印 次: 2011年11月第1次印刷

定 价: 36.00元

凡所购买电子工业出版社图书有缺损问题,请向购买书店调换。若书店售缺,请与本社发行部联系,联系及邮购电话:(010)88254888。

质量投诉请发邮件至 zltts@phei.com.cn, 盗版侵权举报请发邮件至 dbqq@phei.com.cn。

服务热线:(010)88258888。

前 言

质子交换膜燃料电池（PEMFC）具有低噪声、清洁环保、电流密度和比功率高、发电效率高等优点，它不仅可用于航天、军事等特殊领域，而且随着制造成本的降低和电堆系统性能的优化，在电动汽车、混合动力机车、燃料电池电站等方面都具有很大的市场潜力。质子交换膜燃料电池系统安全高效、长时间地运行，需要对其操作条件（空气流量和压力、温度、湿度等）进行有效的控制，而且相关变量之间的耦合性很强，因此质子交换膜燃料电池系统控制是一个多输入/多输出、强耦合的复杂系统控制问题。燃料电池系统优化控制要提高燃料电池系统工作效率，即对各控制量进行优化控制，提高燃料电池系统的净输出功率（燃料电池堆发出的电力减去各辅助系统消耗的电力）；燃料电池系统是一个电源系统，动态响应要求高，而燃料电池堆及其辅助系统自身存在着时滞特性，需要深入研究燃料电池系统控制策略，提高燃料电池系统的动态响应能力；目前，燃料电池在实验室稳态运行条件下的使用寿命远远大于室外动态工况下的使用寿命，因此也需要合适的控制策略提高室外动态工况下燃料电池的使用寿命。

本书紧密结合当前质子交换膜燃料电池的研究热点，对质子交换膜燃料电池系统建模与优化控制的研究现状进行了较为详尽的分析和总结。

全书共分为 6 章，第 1 章为绪论，介绍了质子交换膜燃料电池的基本原理，以及在汽车、舰船、固定电站、备用电源、移动电源等方面的应用。第 2 章总结了质子交换膜燃料电池系统建模国内外研究现状；建立了质子交换膜燃料电池机理模型，包括电压模型、

阴极流道模型、阳极流道模型、质子交换膜水模型、温度模型及辅助设备模型；并建立了基于 Elman 神经网络的燃料电池模型。第 3 章介绍了质子交换膜燃料电池系统模拟仿真，仿真软件包括输入界面、Simulink 模型和输出界面三部分，可以方便地对燃料电池系统进行仿真；利用该仿真软件，对影响燃料电池系统动态性能的各种因素进行了动态分析和仿真。第 4 章介绍了质子交换膜燃料电池空气供应系统控制，采用 Elman 神经网络预测空气参数随燃料电池堆输出功率和电池堆工作温度等参数变化的趋势，进行空气流量控制和空气压力控制研究，提出自适应神经网络控制方法对燃料电池空气供应系统进行控制。第 5 章主要介绍了质子交换膜燃料电池系统水管理，进行了基于回归神经网络优化的模型预测控制研究，并研究了基于湿度软测量的 PEMFC 水管理。第 6 章在第 4 章和第 5 章的基础上，介绍了质子交换膜燃料电池系统控制，包括质子交换膜燃料电池系统预测控制器设计和基于神经网络优化的 PEMFC 多模型切换控制。全书较系统地介绍了质子交换膜燃料电池系统建模与优化控制的最新成果和发展方向，总结了作者的研究成果。

本书第 1~3 章由张立炎撰写，第 4~6 章由全书海、张立炎、黄亮、卫国爱共同撰写，全书由张立炎统稿。本书是作者及其课题组多年研究的成果，作者在研究过程中得到了武汉理工大学潘牧教授的热情指导，课题组研究生张天贺、蒋卫、杜文朝等也先后参与了相关研究工作，在此一并表示感谢。

由于作者水平有限，书中难免存在一些错误和不足之处，恳请广大同行、读者批评指正。

作者

2011 年 5 月

目 录

第 1 章 绪论	1
1.1 概述	1
1.2 燃料电池工作原理	2
1.3 质子交换膜燃料电池应用	4
1.3.1 燃料电池汽车	4
1.3.2 燃料电池舰船	10
1.3.3 燃料电池固定电站	13
1.3.4 燃料电池通信备用电源	15
1.3.5 移动电源	16
1.4 燃料电池系统建模与优化控制研究	17
第 2 章 质子交换膜燃料电池系统建模	20
2.1 燃料电池系统结构	20
2.2 燃料电池系统建模研究现状	21
2.2.1 稳态模型和动态模型	21
2.2.2 燃料电池子系统建模	22
2.2.3 燃料电池系统模型	27
2.2.4 几种商业化软件与模型	29
2.3 质子交换膜燃料电池机理模型	31
2.3.1 燃料电池电压模型	31
2.3.2 阴极流道模型	34
2.3.3 阳极流道模型	36
2.3.4 燃料电池质子交换膜水模型	37
2.3.5 燃料电池温度模型	48

2.3.6	辅助设备模型	50
2.3.7	小结	55
2.4	燃料电池系统神经网络建模	56
2.4.1	非线性动态系统神经网络辨识	57
2.4.2	Elman 神经网络算法分析	65
2.4.3	基于 Elman 神经网络的燃料电池系统辨识	71
2.4.4	模拟仿真及结果分析	80
2.4.5	小结	81
第 3 章	质子交换膜燃料电池系统模拟仿真	82
3.1	概述	82
3.2	燃料电池系统模拟仿真软件开发	83
3.2.1	输入界面	83
3.2.2	Simulink 模型	84
3.2.3	输出界面	85
3.3	燃料电池动态分析及仿真结果	85
3.4	小结	101
第 4 章	质子交换膜燃料电池空气供应系统控制	102
4.1	空气供应系统模型	102
4.2	PEMFC 空气供应系统控制国内外研究现状	103
4.3	PID 控制	109
4.3.1	PID 控制算法	109
4.3.2	控制方法实现	110
4.3.3	PID 控制仿真结果及分析	111
4.4	PEMFC 空气参数解耦设计	112
4.4.1	多变量过程控制系统解耦理论	113
4.4.2	PEMFC 空气参数解耦设计	114
4.5	空气流量控制策略研究	120
4.5.1	控制系统结构	121
4.5.2	空气流量 Fuzzy-PID 复合控制	122

4.5.3	空气流量神经 PID 控制	130
4.5.4	空气流量不同控制策略比较与分析	133
4.6	空气压力控制策略研究	133
4.6.1	控制系统结构	134
4.6.2	基于参数辨识模型的神经 PID 控制	136
4.6.3	基于神经网络辨识模型的神经 PID 控制	146
4.6.4	空气压力不同模型控制策略比较与分析	150
4.6.5	小结	150
4.7	基于自适应神经网络的空气供应系统控制	152
4.7.1	状态空间模型	152
4.7.2	神经网络模型	153
4.7.3	自适应神经网络控制器	154
4.7.4	仿真结果	156
第 5 章	质子交换膜燃料电池系统水管理	159
5.1	概述	159
5.2	基于回归神经网络优化的模型预测控制	160
5.2.1	模型预测控制的表示	163
5.2.2	基于回归神经网络优化的模型预测控制的体系结构	168
5.2.3	收敛性分析	170
5.2.4	仿真结果	173
5.3	基于湿度软测量的 PEMFC 水管理	177
5.3.1	燃料电池电堆的湿度控制模型	179
5.3.2	控制系统的网络结构	180
5.3.3	控制系统的模糊逻辑设计	182
5.3.4	控制系统的学习算法	184
5.3.5	仿真结果	186
第 6 章	质子交换膜燃料电池系统控制	190
6.1	概述	190
6.2	国内外研究现状	191

6.2.1	传统方法	191
6.2.2	预测控制	191
6.2.3	模糊控制	192
6.2.4	神经网络控制	192
6.2.5	自适应控制	193
6.2.6	鲁棒控制	194
6.3	质子交换膜燃料电池系统预测控制器设计	195
6.3.1	燃料电池发动机预测模型	196
6.3.2	基于神经网络自适应 PID 的预测控制	197
6.3.3	基于模糊推理的反馈校正技术	201
6.3.4	燃料电池发动机预测控制仿真与分析	204
6.4	基于神经网络优化的 PEMFC 多模型 切换控制	207
6.4.1	切换系统的优化控制	209
6.4.2	混合神经网络优化	211
6.4.3	仿真结果	214
6.4.4	小结	221
	参考文献	222
	符号及下标说明	240

第 1 章 绪 论

1.1 概 述

能源是发展国民经济和提高人民生活水平的重要物质基础，也是直接影响经济发展的一个重要因素。人类社会对能源的需求越来越大，但人类赖以生存的三大化石能源（煤、石油、天然气）正在减少。世界能源组织调查显示，以现有的能源资源储量，石油不出几十年就会消耗殆尽，煤也只能供人类用 200 年左右。另外，随着人类物质文明的进步，人类对自身生活环境质量的要求也越来越高，而传统能源的消耗造成了严重的环境污染，如煤和石油的燃烧排放出大量的二氧化碳、二氧化硫、一氧化碳和氮氧化物，它们是导致温室效应、酸雨、臭氧层面积减小和光化学烟雾形成的主要原因。传统能源结构及其利用方式越来越难以适应人类生存发展的需要。新的能源利用技术将不断地被开发并利用起来，燃料电池就是一种潜力巨大的新能源。

燃料电池是一种将氢燃料和氧化剂之间的化学能通过电极反应直接转化成电能的装置。它从外表上看有正负极和电解质等，像一个蓄电池，但实际上它不能“储电”，而是一个“发电厂”。燃料电池被誉为继水力、火力、核电之后的第四代发电技术，正在美、日等发达国家崛起，以急起直追的势头快步进入以工业规模发电的行列。燃料电池具有能量转换效率高、低温快速启动、低热辐射和低排放、运行噪声低、适应不同功率要求等优点，具有非常好的前景。

1.2 燃料电池工作原理

燃料电池根据电解质的性质不同，可分为碱性燃料电池（Alkaline Fuel Cell, AFC）、磷酸燃料电池（Phosphoric Acid Fuel Cell, PAFC）、熔融碳酸盐燃料电池（Molten Carbonate Fuel Cell, MCFC）、固态氧化物燃料电池（Solid Oxide Fuel Cell, SOFC）和质子交换膜燃料电池（Proton Exchange Membrane Fuel Cell, PEMFC）。

PEMFC 的电解质是一种固态高分子聚合物，所以它又被称为高分子电解燃料电池（Polymer Electrolyte Fuel Cell, PEFC），即用固体高分子膜做电解质，将氢和氧的化学能通过电极反应直接转换成电能的新型发电装置。图 1.1 为 PEMFC 工作原理示意图。





图 1.1 PEMFC 工作原理示意图

PEMFC 的基本结构主要由阳极、阴极、电解质和外电路组成，其电解质将电池分隔成阴极与阳极两部分。在阳极中，氢气在催化剂的作用下，降低活化能，离解成氢离子与电子：



氢离子通过质子交换膜往阴极移动，而电子则经由外电路对外负载做功后移往阴极。阴极的反应则是氧分子、电子及氢离子

在催化剂的作用下发生还原反应，生成水：



PEMFC 反应除了产生水与电子之外，还会产生热，为了保持燃料电池在低温（<85℃）下工作，必须进行冷却。在 PEMFC 的典型工作温度下，阴极生成的水以液态水与水蒸气的形态同时存在，这些产物将由空气带离燃料电池。

虽然燃料电池单体电压不高（正常工作时电压在 0.5~1.2V 之间），但若干个单体电池串联起来就可以达到数百伏电压。在实际使用时根据所需功率和电压将若干个单体电池串联组成电堆，大功率燃料电池通常由几百片单片电池串联组成。

燃料电池系统从本质上说是水电解的逆装置，氢气和氧气在燃料电池中通过电化学反应生成水，并释放出电能。它是一个大的发电系统，由燃料电池堆、辅助系统（包括氢气供给系统、空气供给系统、加湿系统、热管理系统）及控制系统（通过传感器采集相关信号，控制各种阀、泵和风机等，调节水、热、气的供给）组成。

燃料电池堆由大量的电池单体（几片到几百片）组成，而电池单体主要由膜电极（阴极和阳极）、密封圈和带有导气通道的集流板组成。集流板通常由石墨制成，由于其两侧均刻有导气通道，因而集流板也被称为双极板。膜电极的中间为质子交换膜，它除了有质子交换功能外，还可以起到隔离燃料气和氧化剂气体的作用；膜两边是气体电极，它由兼做电极导电支撑体和气体扩散层的碳纸和催化剂组成。PEMFC 的工作方式如下：氢气和氧气通过双极板上的导气通道分别到达电池的阴极和阳极，反应气体通过电极上的扩散层到达质子交换膜。在膜的阳极一侧，氢气在阳极催化剂的作用下离解为氢离子（质子）和带负电的电子。氢离子以水合质子的形式，在质子交换膜中从一个硫磺基转移到另一个硫磺基，最后到达阴极，实现质子导电。质子的这种转移导致阳极

出现带负电的电子积累，从而变成一个带负电的端子（负极）。与此同时，阴极的氧分子与催化剂激发产生的电子发生反应，变成氧离子，使阴极变成带正电的端子（正极），其结果就是在阳极的带负电终端和阴极的带正电终端之间产生了一个电压。如果此时通过外部电路将两极相连，电子就会通过回路从阳极流向阴极，从而产生电能。同时，氢离子与氧离子发生反应生成水。

氢气供给系统为燃料电池系统提供燃料——氢气，氢气一般由氢气瓶供给，要保持一定的压力。

空气供给系统向燃料电池系统鼓入空气，提供氧化剂——氧气，空气要保持流量和压力。

加湿系统对燃料电池堆中的水进行控制，因为水太多会淹膜，水太少会阻碍质子在膜中的传递，两者都会使燃料电池堆电压降低，从而使燃料电池系统输出功率下降。

热管理系统对燃料电池堆内的温度进行控制，燃料电池系统除了发电之外，还会产生大量的热，因此需要及时将电池生成热带走，否则会发生过热，烧坏电解质膜，使燃料电池系统不能工作。

1.3 质子交换膜燃料电池应用

质子交换膜燃料电池在燃料电池汽车、舰船、固定电站、通信备用电源及移动电源方面得到很多应用。

1.3.1 燃料电池汽车

随着经济的发展，环境问题和能源危机问题日益突出，严重影响了人类社会的可持续发展。传统的汽车内燃机由于卡诺循环的限制，由发动机经驱动系统到车轮的综合效率只有 11% 左右，使汽车消耗了大量的石油，排放了大量尾气，从而使全球能源和环

境污染问题更加突出。燃料电池尤其是质子交换膜燃料电池具有噪声低、无污染、能量转换效率高和工作温度低等良好性能，特别适合做电动汽车动力源。各国政府、企业和科研机构都着重致力于研究质子交换膜燃料电池电动汽车，而燃料电池系统（又称燃料电池发动机）作为燃料电池电动汽车的心脏目前处于新的突破期，正在成为新的研发热点。

世界上第一轮燃料电池汽车研发高潮出现在 2000 年。当时，美国、欧洲和日本的各大汽车生产厂家，都在加紧开发燃料电池技术。企业界尤其是各大汽车生产厂家看到燃料电池巨大的市场潜力，纷纷投入巨资，组成联盟，进行燃料电池汽车的相关研究、实验与生产。各大汽车公司，包括奔驰、通用、丰田等都认为，到 2004 年燃料电池汽车将能够批量生产，实现产业化。戴姆勒-克莱斯勒甚至宣称，预计届时燃料电池汽车的售价将降至每台约 18100 美元。美国能源部长佩耶 1998 年在接受《纽约时报》的采访时也作出自己如意的预测：燃料电池进入家庭、汽车和其他领域的步伐将比人们想象的要快得多。

然而，事实却并非预料中的那么乐观。2003 年 7 月，最早将燃料电池汽车投入商业运营的日本丰田汽车公司，召回了其出租的 6 辆燃料电池汽车，并宣布推迟另外 6 辆燃料电池汽车的租赁。原因是储存氢燃料的高压氢气罐在加注氢气时出现了泄漏。几乎与此同时，各个国家都在燃料电池汽车的试运行中，发现了一系列防不胜防、需要马上就解决的难题。于是国际社会关于燃料电池汽车未来的预测改成了“要达到产业化至少要到 2015 年之后”。而对于燃料电池产业化的瓶颈，国际社会普遍认为是寿命和成本问题。当前，国际上燃料电池汽车进入了第二轮研发高潮，与前些年的热血沸腾、踌躇满志相比，现在人们对燃料电池汽车的研究持更加冷静的态度。2000 年之前，各国主要投入造车和示范；从 2001 年到现在，各国在继续进行示范的同时，都将重点转向应用基础研究，希望通过研究燃料电池各种基础性的问题，找到解

决车用燃料电池寿命问题的根本办法（如研究氢能本身的技术问题、制氢和储氢技术、高效的氢能转换技术等），即找到解决车用燃料电池（汽车的动力源）动态响应、环境适应性与降低贵金属担量等影响电池寿命、成本的办法。中国工程院院士、大连化学物理研究所燃料电池工程中心总工程师衣宝廉在谈到燃料电池汽车的未来走向时感慨地说：“氢源燃料电池汽车要真正走向商业化不是百米冲刺，而是厚积薄发的长跑。”

近几年来，各国政府、各大汽车公司及研究机构继续探索与实践燃料电池在电动汽车上的应用，取得了令人瞩目的成果。燃料电池示范项目在北美、欧洲与日本持续开展。示范的城市与车型在不断增加。Fuel Cell 在 2009 年 8 月发表的统计数据显示，目前世界范围内的加氢站已有 200 余个，在美国的加氢站已有 73 个。燃料电池汽车示范项目中最具代表性的是欧洲历时两年的燃料电池电动汽车演示项目（CUTE），27 辆客车在 9 个城市累计运行 62000 小时，行驶 85 万公里，承载乘客约 400 万。为了继续示范这些燃料电池公共汽车和基础设施，欧盟决定继续出资 1900 万欧元支持项目二期示范，即 HyFleet: CUTE 项目。到目前为止，示范的 36 辆燃料电池公共汽车已累计运行 250 多万公里。美国加利福尼亚州燃料电池伙伴合作计划（CaFCP）燃料电池示范项目也是其中的重要代表，它是汽车公司、燃料供应商、燃料电池技术公司和政府机构合作的项目。其伙伴成员有 32 个公司和组织，包括戴姆勒 克莱斯勒、福特、通用、本田、现代、尼桑、丰田、大众、Ballard、UTC、BP、Exxon Mobil、Shell、Chevron Texaco、加州能源委员会、加州南海岸空气质量管理局、美国能源部、美国交通部等。该项目于 1999 年起动，到 2008 年年底，在加利福尼亚州已有 200 余辆燃料电池汽车和 26 个加氢站。至 2009 年 5 月，在美国实际道路上行驶的燃料电池汽车已经超过 300 辆。近期，加州交通局在原有 3 辆燃料电池客车已运行 16.5 万英里后，又订购了 12 辆装备 UTC Power 的 Van Hool 客车。预计到 2014

年，在加州将有 4300 辆燃料电池轿车交付使用。如图 1.2 所示为各大汽车公司生产的燃料电池轿车。



图 1.2 各大汽车公司生产的燃料电池轿车

燃料电池巴士示范运营取得了很大进展。UTC 公司将型号为 PureMotion 120 的燃料电池发动机装载于 Alameda-Contra Costa Transit District（一家城市公交公司，简称 AC Transit）公交巴士上，在加利福尼亚州的奥克兰市进行测试，完全使用初始电堆而不更换电池，结果一台发动机正常运行时间超过 7000 小时，而另一台发动机运行时间也超过 6000 小时。3 辆配备了 UTC Power 燃料电池系统的 AC Transit 巴士至今已正常行驶了 25.5 万英里（约 41 万公里），平均燃料经济性比相同工况下行驶同样路线的柴油机巴士高 65%。以燃料电池作为动力源的公交巴士能在减少温室气体排放方面作出很大贡献，如果氢气来自重整天然气，则与柴油机巴士相比，温室气体排放量能降低 43%；如果氢气完全来自固定的可再生能源如太阳能和风能，则温室气体排放量能降低 100%。如图 1.3 所示为各大汽车公司生产的燃料电池巴士。



(a) 戴姆勒-克莱斯燃料电池巴士



(b) Citaro燃料电池巴士



(c) Ballard燃料电池巴士



(d) UTC燃料电池巴士

图 1.3 各大汽车公司生产的燃料电池巴士

国际上在燃料电池商业化方向的努力近期也取得了突破性进展。截至 2010 年 6 月 29 日，美国 UTC 公司研发的 PureMotion 燃料电池在 AC Transit 的燃料电池电动汽车上，实际运行超过了 7000 小时，没有更换其中任何的电池部件，展现了解决车用燃料电池寿命问题的希望；美国通用公司研发的燃料电池系统体积已和相同功率的内燃机接近，系统功率密度达到适用水平；日本丰田公司的车用燃料电池的铂催化剂用量减至原来的 $1/3$ ，成本随之大幅降低。在加拿大的 2010 年温哥华冬奥会上，有 20 辆燃料电池客车投入使用，并在冬奥会后继续运行。加拿大的 Hydrogenics 公司已经拿到为商用卡车提供 HyPM16 燃料电池系统的合同。Ballard 公司在 2010 年年初又得到 480 万加元的政府资助，进一步发展燃料电池巴士。2011 年，加拿大宣称世界上第一个小规模

的氢液化厂将在北温哥华建立。2011年6月,奔驰公司的B级豪华旅行燃料电池电动汽车在进行为期70天的环球旅行后,回到起点斯图加特,航程达3万公里。

世界各国及各大汽车公司都瞄准在2015年实现燃料电池汽车的产业化。2009年,欧盟设立了为期6年的燃料电池和氢能技术行动计划的课题(The Fuel Cells and Hydrogen Joint Technology Initiative),以攻克燃料电池技术规模产业化之前的技术和政策方面的难题,总经费达9.4亿欧元。目标是解决技术瓶颈,实现突破,促进企业下定实现产业化的决心,争取在2015—2020年实现市场大规模增长。德国高度重视氢燃料电池技术的产业化,设立的国家创新计划项目经费达14亿欧元。美国、加拿大、日本等也制订了类似的计划,继续加大对燃料电池基础问题的研究和燃料电池的应用研究。日本三大汽车公司宣称2015年实现燃料电池汽车量产,通用汽车公司提出2015年开始年产燃料电池汽车数千辆,成本仅为当前水平的25%。

我国车用燃料电池技术经过“九五”、“十五”的持续发展,特别是“十一五”期间在科技部863计划“节能与新能源汽车重大项目”的资助下,燃料电池电动汽车技术得到了显著的提升。燃料电池轿车成为了2008年北京奥运“绿色车队”中的重要成员,经受了酷热多雨天气和频繁启停城市工况等的考验,20辆燃料电池轿车运行总里程为7.6万公里,车辆执行任务970车次,单车出勤率超过90%。作为“中国燃料电池公共汽车商业化示范项目”的一部分,燃料电池城市客车自2008年7月以来在北京进行为期一年的示范运行,为燃料电池商业化进一步积累经验、收集数据。其后,我国自主研发的16辆帕萨特领驭氢燃料电池轿车于2009年在美国加州进行为期半年的道路测试与示范运行服务。2010年,我国研发的近200辆燃料电池客车、燃料电池轿车和观光车在上海世博会期间示范运行,电池堆性能及系统稳定性表现良好,取得了令人瞩目的成果。

1.3.2 燃料电池舰船

美国 Analvtio Power (AP) 公司的研究表明, PEMFC 是符合水面舰艇动力要求的集中动力系统中的最佳方案。荷兰海军的研究表明, 如果 M 型护卫舰的能源供应系统采用燃料电池 柴油机混合设计, 则和平时期节约燃料 25%~30%。美国海军计划在 2011 年实现 2.5MW 电堆用于驱逐舰, 最终目标是 25MW 电堆。

20 世纪 60 年代初, 燃料电池在航天领域成功地应用后, 很多国家对燃料电池用于潜艇发生了兴趣, 认为燃料电池潜艇有可能成为非核动力的真正潜艇。20 世纪 60 年代至 80 年代末, 燃料电池研究跌宕起伏, 曾几起几落。直到 20 世纪 80 年代德国将碱性燃料电池系统 (AFC) 装在 205 级 U1 艇上并成功地进行了海上试验, 才引起了世界各国对潜艇用燃料电池的极大关注, 一些国家重新参与或重新启动潜艇用燃料电池的研制工作。近 10 年来, 潜艇用燃料电池 AIP 技术迅猛发展, 近期在造、订购和即将交付使用的燃料电池 AIP 潜艇约 20 余艘。现阶段开发的燃料电池 AIP 潜艇最成功的例子是德国的 212 型潜艇和 214 型潜艇, 除德国海军的订单外, 还出口国外。燃料电池用于潜艇具有以下优点。

(1) 能量转换效率高

燃料电池的效率不受卡诺循环的限制, 现在已经达到 60%~70%; 使用甲醇作为燃料时, 其效率也可达到 55%~60%。斯特林发动机效率只有 38%, 闭式循环柴油机效率小于 30%, 而且它们必须将机械能转化为电能后方可使推进电机运行。这就意味着燃料电池的燃料和氧消耗量只有其他动力装置的一半。潜艇水下续航力要求越高, 燃料电池的高效率体现出的优越性就越明显。

(2) 噪声很小

燃料电池本身无运动部件, 可在完全无声状态下工作, 只有辅助系统中的微型循环泵会发出低微的噪声。

(3) 反应产物是水，不需要后处理系统

各种热机的工作产物都有二氧化碳和其他废气。若直接排出艇外，则要消耗动力，并且会产生航迹；若用化学药品吸收（如用碱石灰或其他化学物质吸收），则必然增加重量和体积。燃料电池反应产物是水，可留在艇内，也可排出艇外。

(4) 可直接用纯氧工作

潜艇 AIP 系统用的氧化剂为液态氧，经汽化后进入燃料室或燃料电池。对热机来说，如果直接用纯氧工作，则会产生很高的温度，一般材料受不了，必须用其他气体（也可用反应产物气体）稀释后方可进入热机，这就增加了供氧系统的复杂性，相应地增加了系统的重量和体积。但燃料电池可用纯氧工作，比用混合气体输出的功率要高；而且供氧系统简单，节约了宝贵的体积和重量。

(5) 红外辐射小

采用质子交换膜燃料电池，其工作温度只有 80℃ 左右，其红外辐射强度比采用其他 AIP 系统造成的红外辐射强度低得多，有利于提高潜艇隐蔽性。

(6) 模块结构，便于维修

燃料电池组的电池模块由若干单元电堆串、并联组成，便于安装、维护和修理，而且便于更换新电堆，提高了动力系统的可靠性和可维修性。

如图 1.4 所示为德国海军 U212A 级燃料电池潜艇。动力源由柴油机和质子交换膜燃料电池组成，高速行驶时用柴油机，低速潜伏时用燃料电池。燃料电池动力系统由 9 组 PEMFC 模块、14 吨液氧贮存柜和 1.7 吨气态氢贮存柜 3 部分组成。潜伏时间可达 3 周，是普通潜艇的 5 倍。至 2008 年，德国海军已订购了 4 艘这种潜艇，合同金额为 14 亿欧元。希腊和韩国各订购了 3 艘 U214。意大利是参与研发国家，已经参照德国海军的 U212A 建造了两艘相同的潜艇。2006 年德国海军的一名发言人宣布，U212A 级 U32 型

潜艇载有 27 名船员，从德国埃肯弗尔德湾出发，到达西班牙罗塔岛海军基地，持续在水下航行两周，刷新了非核动力潜艇连续潜航时间的世界纪录。



图 1.4 德国海军 U212A 级燃料电池潜艇

2006 年 9 月，上海海事大学研制的氢燃料电池船“天翔 1 号”在上海青浦水域进行了试航。14 立方米氢气可支持小艇以 14 公里的时速连续航行 5 个小时。中科院大化所 2002 年开始研制燃料电池无人水下航行器 (UUV)。以 UUV 为平台，设计燃料电池电电混合动力系统，燃料电池提供平均功率，辅助电池提供加速或高速时所需的额外功率。20kW 燃料电池 UUV 的性能指标为：额定功率 20kW，峰值功率 60kW，潜航时间 ≥ 24 小时，系统寿命 ≥ 5000 小时。

1.3.3 燃料电池固定电站

PEMFC 不仅可以作为交通电源,而且可以用于固定电站。它既可与电网系统互连,用于调峰;也可作为独立电源,用做海岛、山区、边远地区或国防(人防)发供电系统电源。采用多台 PEMFC 发电机联网还可构成分散式供电系统。分散式供电系统有很多优点。

(1) 可省去电网线路及配电调度控制系统。

(2) 有利于热电联供(由于 PEMFC 电站无噪声,可就近安装,PEMFC 发电所产生的热可进入供热系统),可使燃料总利用率达到 80%以上。

(3) 战争和自然灾害等影响比较小,尤其适应现代战争条件下的主动防护需要。

(4) 通过天然气、煤气重整制氢,可利用现有天然气、煤气供气系统等基础设施为 PEMFC 提供燃料,通过再生能源制氢(电解水制氢、太阳能电解制氢、生物制氢)则可形成循环利用系统(这种系统特别适用于边远地区),使系统建设成本和运行成本降低。国际上普遍认为,随着燃料电池的推广应用,发展分散型电站将是一个趋势。

早在 1988 年,当 PEMFC 技术刚刚显示出其灵活性和可靠性时,Dow 化学(加拿大)公司就对这种技术在固定电站上的应用产生了兴趣,并在安大略省能源厅的支持下,与巴拉德公司合作研究制造了一套 10kW 级的 PEMFC 发电系统,其目的是要检验在一个工厂环境内,以工业级富氢气为燃料的 PEMFC 发电装置的性能及可靠性。这套系统直接安装在 Dow 化学公司下属的 Sarnia 分部的氯碱厂内,以化工厂副产品氢为燃料。整个系统设计成全自动操作,试验参数的收集与系统控制均由计算机完成。整个系统在 1990 年 5 月进行了首次运行,功率大于 5kW。经过数月试验运行后,通

通过对收集的数据进行研究分析, 又对操作系统、电池设计和膜本身进行了改进, 延长了系统运行周期, 1991 年 2 月该系统试验运行功率达到 10kW。随后, 在加拿大和不列颠哥伦比亚政府的资助下, 巴拉德公司于 1994 年推出了同样以化工厂副产品氢为燃料的 30kW 的 PEMFC 发电装置。在此基础上, 巴拉德公司与美国 GPU 公司、法国 GEC ALSTHOM 公司合资成立了巴拉德发电系统公司 (Ballard Generation Systems, BGS), 专门生产固定式电站 (源), 同时开始开发以天然气为燃料的 PEMFC 电站, 并于 1995 年成功完成 10kW 级天然气燃料的 PEMFC 固定式发电设备的安装和示范运行。1998 年 6 月, 巴拉德公司宣布 BGS 公司获得 GEC ALSTHOM 公司 1100.6 万加元的订单, 用于购买 4 套 250kW 级天然气 PEMFC 发电装置。

2010 年 1 月, 300kW 质子交换膜燃料电池示范电站落户广州大学城, 该电站由华南理工大学设计与建造, 占地 2000 平方米, 可以实现 24 小时运转, 产生的电流直接输送到华南理工大学的 380V 低压电网上, 满负荷运行时可满足华南理工大学国际学术中心正常运营所需。

质子交换膜燃料电池还可以用在住宅热电联供系统中, 据报道, 其供电效率可达 40% 以上, 热电综合效率超过 80%。如果用燃料电池热电联供系统替代天然气热水器, 则能量利用效率可以提高一倍, 节能 1/3。日本政府为燃料电池热电联供系统的生产商提供 50% 的价格补贴, 使用户在几年内收回购买装置的投入; 价格补贴的效果不错, 2008 年年底日本家庭拥有 3000 多台燃料电池热电联供系统, 到 2010 年 5 月已增长到 5000 多台。东京燃气和松下将从 2011 年 4 月 1 日开始销售新的家用燃料电池热电联供系统, 估计实售价格为 100 万~150 万日元 (相当于 8 万~12 万元人民币), 力争两年后每年订单达到 1 万台。其额定输出功率由现有产品的 1kW 改为 750W。通过降低额定输出功率, 实现了燃料电池组及将管道燃气改质为氢气的燃料处理器等核心部件的小型化和

低成本化。另外，通过降低额定输出功率，支持 250W 起步的部分负荷运转。现有产品为 300W 起步。据悉，由于家电产品的待机耗电量不断降低，夜间利用时要求实现更低输出功率的部分负荷运转。考虑到缺少加注设施对燃料电池发展是重要制约，因此瞄准 2015 年规模化应用燃料电池的日本、韩国、美国，都加快了加注设施网络的建设速度。

1.3.4 燃料电池通信备用电源

在自然灾害中，电信设施缺乏足够的备用电源是引起网络中断的主要原因，并由此延缓了重建工作。这些危机提升了备用电源的重要性，并且促使电信服务商制订灵活持续的商业计划来解决对耐用备用电源的需求，从而增加网络的可靠性和稳定性。许多已建的基站已经使用阀门控制铅酸电池（VRLA）组在停电期间提供长达 4 小时的备用电源。一些大型的或位于城市中心的基站则使用柴油发电机提供备用电源。但是当今飞速发展的电信网络往往需要长时间电力供应，4 小时的备用电源供电明显不足，尤其是在电网供电不现实或者自然灾害频繁发生的情况下。安装适当规模的燃料电池系统是一个替代选择，可以为电信负载提供所需要的电力。在电网停电期间，只要保证氢气供应就能连续提供电源。氢气可以用钢瓶形式运送到现场，也可以通过天然气或其他化石燃料现场转化的方式获得。

2008 年，美国能源部公布了一项加速固定燃料电池在通信备用电源方面商业化的基金。2009 年，以斯普林特·纳克斯泰尔为首的财团、质子交换膜燃料电池制造商。ReliOn 和 Alteryx，以及氢气和储氢罐供应商美国空气化工公司等获得了这笔基金。美国 ReliOn 公司从事燃料电池备用电源生产，该公司 T-2000 的每一模块的功率约为 2kW，总功率有 2kW，4kW，6kW，8kW，12kW 等。

2009 年 11 月，武汉市江夏区梁子湖移动通信基站安装了我国

第一台商业化通信基站燃料电池备用电源。截至 2010 年年底，绿色环保的燃料电池备用电源具备的高稳定性和持久供电的优点成功地保证了该基站在示范期内零掉线，为通信行业的节能减排和创新作出了积极贡献。通信基站燃料电池备用电源具有无污染、体积小、效能高、寿命长等优点。目前，我国的无线通信基站备用电源主要使用铅酸电池，其寿命一般只有 3~5 年，一个小型基站就需要 1.5 吨的铅酸电池，且极易造成铅污染。燃料电池备用电源可使用 15~20 年，全部重量也不过 380 千克，其反应物就是纯净无瑕的水，完全无污染。同时铅酸电池一般仅能维持通信基站 2 小时左右的供电，而燃料电池则能在 6 个储氢罐的持续供气下，支持移动通信基站连续运转 48 个小时。截至 2010 年 12 月底，梁子湖移动通信基站燃料电池备用电源一年多来运行正常，运行一年后再次检测，各项运行数据和指标完全符合移动公司无线基站备用电源使用标准。梁子湖移动通信基站燃料电池备用电源的使用标志着我国燃料电池工业化应用已正式起步，同时也是我国通信领域走向绿色低碳的重要标志。

1.3.5 移动电源

PEMFC 可作为便携式电源、小型移动电源等，适用于军事、通信、计算机等领域，以满足应急供电和高可靠性、高稳定性供电的需要。实际应用是手机电池、笔记本电脑等便携电子设备电池、军用背负式通信电源、卫星通信车载电源等。对于 PEMFC 在便携式电源方面的应用，巴拉德公司和美国氢能（H Power）公司的成绩最为显著。除了用于笔记本电脑的 PEMFC 系统外，巴拉德公司还与 Ball Aerospace 和 Hydrogen Consultants 公司合作，于 1997 年为美国国防部研制出 100W 的 PEMFC 系统。该系统采用常压空气为氧化剂和冷却剂，空气通过两个小风扇供给；以纯氢为燃料，采用不同的燃料储存方式，如化学氢化物储氢、高压气态储氢、

金属氢化物储氢等，该系统可分别提供 13kWh、5kWh 和 1.5kWh 的能量。美国机械技术公司（MTI）首席执行官彭尼·利姆说，虽然目前的燃料电池多用于汽车电源，在体积上都较为庞大，但他们已经开发出了能用于手机的便携式燃料电池。其实早在 2008 年年底，MTI 公司就推出过一款以甲醇为燃料的便携式燃料电池。该公司宣称，这种燃料电池可为便携式电子设备提供 8~10 小时电源供应，而换成同样规格普通锂电池，续航时间则仅为两三个小时。

1.4 燃料电池系统建模与优化控制研究

要想燃料电池系统安全高效、长时间地运行，必须对其操作条件进行有效的控制，如风机控制电压、氢气瓶阀门开度、冷凝器控制电压和加湿器转速等。这些操作条件都有一些限制，如风机鼓入的风量不足会使电堆输出电压降低，鼓入的风量超过一定范围不会使电堆输出电压继续升高。一般来说，空气的过量系数（鼓入的空气量和需要的空气量之比）为 2 比较合适；加湿器转速控制加湿水量，将燃料电池堆内的水控制在一个合适的范围内；冷凝器控制电压控制燃料电池堆内的温度，温度高会增加燃料电池的活性，提高输出电压，但过高的温度会烧坏电解质膜，因此燃料电池堆内的温度要控制在合适的范围内。这些控制量之间的耦合性很强，如鼓入的风量加大，会降低电堆内的温度和电堆内的水量；电堆内的温度升高，会降低电堆内的水量；电堆内水量多会阻碍流道，降低风量和电堆内的温度等。因此对燃料电池系统这样一个多输入/多输出、强耦合的复杂系统进行优化控制，使其经济性、动态响应及耐久性兼优，是燃料电池研究的热点和难点。具体来说，燃料电池系统的优化控制要达到如下目标。

（1）降低燃料电池系统“油耗”

对各控制量（风机控制电压、氢气瓶阀门开度，冷凝器控制电压和加湿器转速）进行优化控制，可以提高燃料电池系统的净输出功率（燃料电池堆发出的电力减去各辅助系统消耗的电力），使燃料电池系统以最少的氢气发出最多的电力，提高燃料电池系统的效率，降低燃料电池的运行成本。这类似于现在汽车的一个重要指标——百公里油耗，在目前能源供应日趋紧张的形势下，这是一个相当重要的指标。

（2）提高燃料电池系统的动态响应能力

燃料电池系统特别是车用燃料电池系统运行工况和操作条件非常复杂，如汽车需要起动、加速、减速、巡航和刹车等，而燃料电池堆及其辅助系统自身存在着时滞特性，故研究燃料电池系统的优化控制策略，满足运行工况的要求，提高燃料电池系统的动态响应能力，是一个非常重要的课题。

（3）提高燃料电池系统的使用寿命

使用寿命（即耐久性）问题是燃料电池研究面临的重大问题，目前实验室稳态运行条件下的燃料电池系统的寿命大于 50000 小时，而车用燃料电池系统的最高使用寿命据 Ballard 公司报道只有 2200 小时（18 万公里），这与美国能源部提出的目标寿命大于 5000 小时（40 万公里）还相差很远。影响燃料电池系统耐久性的因素很多，而在汽车起停频繁及瞬时加速等工况下，燃料电池系统性能的衰减是很明显的。例如，在负载变化频繁的环境下，风机或空压机将快速频繁地随动变化，引起空气侧压力频繁剧烈波动，长期运行会使质子交换膜性能下降。因此既要满足动态响应要求，又要考虑实际约束条件，提高燃料电池系统的耐久性，也迫切需要优化燃料电池系统的控制策略。

进行燃料电池系统优化控制的研究必须建立燃料电池堆的数学模型，这样就可以在设计阶段通过计算机仿真，模拟在不同的负载电流、反应气体压力、温度、电堆电压条件下系统的特征，

预测燃料电池系统动态响应，这对于设计系统的控制策略是相当有用的。

综上所述，燃料电池优化控制目标为：在负载和工作条件变化的情况下，始终保持燃料电池系统处于良好的运行状态，保证燃料电池系统的高性能、高可靠性和长寿命。随着对燃料电池研究的深入，燃料电池优化控制问题的研究，可以提高燃料电池的效率和使用寿命，降低燃料电池的运行成本，为燃料电池大规模产业化提供技术储备，将在燃料电池研究中占有越来越重要的位置。

第2章 质子交换膜燃料电池系统建模

本章介绍燃料电池系统的基本组成，建立燃料电池系统的数学模型，包括电堆模型和辅助设备模型。其中，电堆模型包括电压模型、阴极流道模型、阳极流道模型、质子交换膜水模型、温度模型；辅助设备模型包括风机模型、氢气循环泵模型、加湿器模型、水循环泵模型、水箱模型、热交换器模型。本章还提出了基于 Elman 神经网络的燃料电池发动机系统模型，并利用该模型进行动态特性研究。

2.1 燃料电池系统结构

燃料电池系统实际上是一个大的发电系统，它由燃料电池堆、辅助系统（包括氢气供给系统、空气供给系统、加湿系统、热管理系统）及控制系统（通过传感器采集相关信号，控制各种阀、泵和风机等，调节水、热、气的供给）组成。燃料电池堆将氢气和氧气中的化学能直接变成电能，生成水，而不需要经过燃烧的过程，是一个电化学装置；氢气供给系统给燃料电池系统提供燃料——氢气，一般由氢气瓶、高压阀、减压阀及氢气循环泵组成；空气供给系统向燃料电池系统鼓入空气，提供氧化剂——氧气，主要的辅助设备是风机，如果是高压系统就采用压缩机，如果是低压系统就采用风机，本书中采用高压系统；加湿系统对燃料电池堆中的水进行控制，因为水太多会淹膜，水太少会阻碍质子在膜中的传递，两者都会使燃料电池堆电压降低，从而使燃料电池系统输出功率下降，加湿系统的主要辅助设备是加湿器；热管理

系统对燃料电池堆内温度进行控制，燃料电池系统除了发电之外，还会产生大量的热，因此需要及时将电池生成热带走，否则会发生过热，烧坏电解质膜，使燃料电池系统不能工作，热管理系统主要包括水循环泵、热交换器和水箱。

燃料电池系统组成示意图如图 2.1 所示。

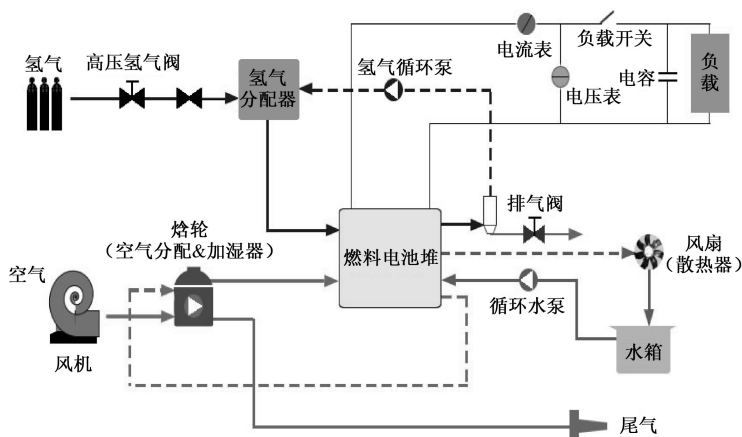


图 2.1 燃料电池系统组成示意图

2.2 燃料电池系统建模研究现状

2.2.1 稳态模型和动态模型

国内外研究者已经对燃料电池模型做了大量工作，包括一维、二维和三维模型，大多数建模研究的目的在于预测燃料电池的性能，据此进行组件的设计和选择。这些模型大多数是稳态的、单电池级的，包含燃料电池的空间参数，主要基于电化学、热动力学和流体力学。它们提供了操作燃料电池堆的有用知识，

但机理复杂、参数多且不易确定、计算时间长，不适合用于燃料电池系统的控制。

质子交换膜燃料电池的稳态模型可以反映燃料电池系统在稳定状态下运行的性能，可用于设计燃料电池系统结构或选择操作点。但对于具体的应用来说，如将燃料电池用于电动汽车或机器人，其动态响应特性就很重要。建立动态模型可以分析起动和关闭过程，在工作循环中分析各种因素的影响，从而减少负载变化时的响应时间。燃料电池的稳态模型较多，如 Bernardi 和 Verbrugge^[1]将膜的水化考虑在内，提出了一个全面的 MEA 模型，Springer 等^[2]结合实验数据，完善了这个模型。Rowe 和 Li^[3]研究了设计和操作条件对电池性能、热量动态反应及水管理的影响。Barbir 等^[4]研究了空气供应和电堆的关系，并提出了几个有助于优化电堆性能的关键因素。Geyer 和 Ahluwalia^[5]研制出了计算机仿真工具 GC，可用于燃料电池系统的设计和分析。燃料电池系统的动态模型相对较少，但近年来发展迅速，下面描述的模型大多数是动态模型。

2.2.2 燃料电池子系统建模

质子交换膜燃料电池堆中，它的动态行为及相应的特征时间对决定电堆的动态性能有极其重要的作用。例如，从开始操作到稳态时的时间间隔就是最重要的特征时间之一。这样的时间间隔依赖于电池的每一组件动态响应时间，其中包括膜中水传输的动态响应时间、反应物动态响应时间、温度动态响应时间。为了得到整个电堆的动态响应，应该先调查每一组件的动态行为，然后按照组件间的相互作用，将组件组合起来，构成一个整体，得出整个系统的动态响应时间。此外，燃料电池作为一个复杂的系统，建模工作量较大，将它分成几个子系统分别研究，再将子系统组合成一个大系统，这也是一个行之有效的研究方法。下面就对电

压模型、空气供应子系统建模、水管理子系统建模和热管理子系统建模分别进行阐述。

1. 电压模型

燃料电池稳态时可以认为由一个可变电压源、欧姆内阻、可变内阻串联构成^[6]。燃料电池等效电压模型如图 2.2 所示， E 代表可变电压源，等效于燃料电池电动势，数值由标准电动势、燃料电池工作温度、燃料及氧化剂的气体压力等参数决定。 I 为燃料电池输出电流，其值由外部负载决定。 R_0 为电池的欧姆内阻，对于给定的燃料电池，在压力、温度一定的条件下，欧姆内阻变化不大。 R_1 为电池电化学极化、浓差极化等效内阻，当电池的各参数确定后， R_1 是压力、温度、输出电流的函数。




图 2.2 燃料电池等效电压模型

在燃料电池堆电压模型中，经常采用经验模型，最经典的半经验模型是 Amphlett^[7] 的 SSEM 模型：

$$\begin{aligned} V_{\text{cell}} &= E_0 + \eta_{\text{act}} + \eta_{\text{ohm}} \\ \eta_{\text{act}} &= \xi_1 + \xi_2 T + \xi_3 T \ln(c_{\text{O}_2}^*) + \xi_4 \ln(i) \\ \eta_{\text{ohm}} &= -iR_{\text{int}} = -i(\xi_5 + \xi_6 T + \xi_7 i) \end{aligned}$$

式中， E_0 为开路电压， i 为电流， T 为电堆的工作温度， $c_{\text{O}_2}^*$ 为催化剂层界面的氧气浓度， $\xi_1 \sim \xi_7$ 为拟合参数。

在此基础上，Mann^[8] 提出的 GSSEM 模型和 Fowler 提出的 GSSEDM 经验模型，考虑了膜的离子电导率随膜中水含量的变化和

电池寿命等因素。

此外，最小二乘拟合和神经网络的方法也被采用，如 Jemei^[9]就采用神经网络的方法，以电堆的电流、温度、氢气压力和氧气压力为输入，电堆电压为输出，建立了燃料电池的电压模型。

2. 空气供应子系统建模

在燃料电池系统的辅助系统中，耗电最多的部件是空压机，因此，电堆和空气系统的匹配和操作优化一直是研究的热点，这方面的报道也较多。

Gelfi^[10]分析了高压系统和低压系统的优劣：在同等功率下，低压系统具有寄生功率小、效率较高的特点，但其体积较大，重量比功率低，高压系统则相反；低压系统的功率动态性能稍好，高压系统的流体动态性能较好。一般来说，系统的工作压力对燃料电池系统的性能影响较大，在过量空气系数的选择上要兼顾燃料经济性和动态性能两方面，多位研究者对各种空压机对系统性能的影响做了研究。其中，空压机的动态响应时间是一个重要的参数，影响整个系统的动态响应。美国加州大学的 Bird 分析了空气系统的时间常数，比较了高、低压系统中空气系统的动态特性。Pukrushpan^[11]给出了电堆电压半经验模型，建立了电堆阴极和阳极的物料平衡方程，以及质子交换膜中的水平衡方程，并对压缩机的动态特性进行了建模，提出了比较完整的电堆和空气系统模型。该模型比较简单，适用于控制中，只是没有考虑温度因素。

3. 水管理子系统建模

为了同时提高能量转换效率和功率密度，必须使 PEMFC 在较高的电流密度下工作时具有较小的电压损失。PEMFC 模拟及其实验分析表明：随着电流密度的提高，电池内阻明显增大，导致电池工作电压急剧下降，其原因并不是膜的阻抗随电流密度增大而增大，主要是电池内失去水平衡，没有满足膜的润湿条件。PEMFC

的电压损失主要有活化损失、欧姆损失和浓差损失。其中，欧姆损失和浓差损失与 PEMFC 内部的水平衡有关，因此，保持 PEMFC 中的水平衡是提高电池性能和寿命的一个关键技术。

PEMFC 中的水有气态和液态两种，其来源包括由电化学反应生成的水（在阴极）和由加湿的反应气体代入的水。通过对 PEMFC 的工作原理的分析可知，燃料电池唯一的反应产物水在阴极由氢气与氧气在催化剂的作用下结合而成，而对反应气体进行加湿处理则是为了使电解质始终保持最佳的湿润状态，从而使电池稳定运行。水过多或过少，对 PEMFC 的性能都会带来负面的影响，这主要表现在以下几个方面。

（1）液态水的凝聚导致传质过程受阻，因为它使氧气通过气体扩散层的速度降低，甚至会淹没电催化剂的活性点。

（2）液态水的存在导致气体在电极内和系统内各单元之间分布不均匀，这将使电池性能下降，并造成系统内各个单电池的电压不等。

（3）反应气体被水蒸气稀释，从而造成反应界面上反应气体的不足。

（4）如果质子交换膜失水过多，其电导率将会下降，导致电池的欧姆压降增大。

（5）质子交换膜中的含水量对电催化活性也有影响，当膜失水后，催化层界面的活性也会下降。

质子交换膜（PEM）中的水传递包括电迁移、浓差扩散和对流 3 种机制。大量的反应气流和水进入电堆阳极和阴极影响着膜的湿度。电池中膜的脱水和湿化过量，会导致膜电阻急剧增大，引起极化电压损失、质子传导能力降低。电池中水失去平衡是由诸多因素造成的，如负载的增大、透过质子膜的反应气流压力的变化、气体流速的变化、电堆温度的变化（改变水蒸气饱和压），如果没有适当的湿度控制，系统可能会出现 20%~40% 的电压降。水管理系统的任务是维持质子膜的湿度和平衡系统中水的用量，水管理

模型可分为质子交换膜水传质模型、电极水管理模型、单电池水管理模型和电堆与系统水管理模型 4 个层次，本书主要关注电堆与系统水管理模型这一最高层次，但这种模型必须建立在前三个层次的深入研究基础之上。质子交换膜水传质模型、电极水管理模型、单电池水管理模型的研究相对较多，而且也比较成熟。而电堆与系统水管理模型的研究和报道相对较少，大多数是对单电池模型进行简单推广。Chen 等^[12]建立了简单的膜中水传递浓度方程，得出了水传递的动态响应时间值，并对影响水传递的参数进行了分析；Pukrushpan^[13]建立了较完整的水传递过程模型，比较适合用于控制中，但模型的准确性有待检验。水管理方法有增湿和排水技术。增湿主要有内增湿、外增湿和自增湿；排水技术主要有流场排水和动态排水，文献[14]对此有较详细的论述。

4. 热管理子系统建模

PEMFC 电堆内部整体温度和温度分布状况对维持电化学反应的正常进行和质子交换膜的长期稳定工作有着重要影响。PEMFC 的温度特性是由其电解质——质子交换膜所决定的。由于目前多数 PEMFC 均采用 Nafion 系列膜作为电解质，而这种膜在温度超过 80℃ 时，其热稳定性和质子传导性能将会严重下降，因而 PEMFC 的最佳工作温度为 80℃ 左右。Dow 化学公司开发的新型离子膜可将 PEMFC 的工作温度提高 10~20℃。燃料电池的工作温度对其性能有十分显著的影响，如一般 PEMFC 产生的热量有燃料和氧化剂气体的预热、电化学反应产生的热和电流在电极内阻上产生的消耗热。PEMFC 在运行中不断产生热量，温度逐渐升高，必须及时排出多余的热量。电堆在不同的负荷条件下，其阶跃响应的时间常数和滞后都不同；从进口反应气体的温度到电堆内部温度变化存在迟延，迟延包括传输迟延、容积迟延和测量迟延。为保持电堆工作温度的恒定，需要由热管理系统将热量排出。而电堆中水的生成和物态变化，对温度的影响较大，所以系统的水、热管理总

是耦合在一起的。Yan^[15]将水平衡方程和能量平衡方程联系在一起，建立了电堆的水热管理模型。马天才等^[16]从实用的角度出发，提出了一种不需要精确的系统内部特性和结构参数的燃料电池温度控制仿真模型。Zhang 等^[17]建立了 PEMFC 电堆热系统的简化模型，可用来分析操作参数对系统性能的影响。

2.2.3 燃料电池系统模型

1. 分布式参数模型

对于燃料电池系统模型，已经有很多研究者提出了三维、二维、一维模型，这些模型虽然计算复杂、难以应用于燃料电池系统实时控制中，但通过它们可以充分了解燃料电池机理，为建立适用于燃料电池实时控制的模型打下基础。其中，一维模型或分布式参数模型更接近控制模型，对此深入了解更有借鉴作用。一维模型的一般假设包括：忽略流道中沿流道方向的压力降；对于气体，假设其为理想气体，遵从理想气体定律；假设液态水在流道表面存在，体积忽略不计，进出电极的水假设是以水蒸气的形式传输的；假设电极层非常薄，忽略通过电极多孔层的气体传输阻力。例如，Bernardi 和 Verbrugge^[1]假设一个固定的液体体积系数，并假设液体和气体没有相互关联条件，建立了多孔电极中简化的一维液态水传输模型；Yi 和 Nguyen^[18]考虑空间变化对燃料电池性能的影响，建立了分布式参数模型，该模型是一个沿流道分布的一维模型，这个模型对后来的分布式参数模型及控制模型很有借鉴意义，有多位研究者引用。Methekar 等^[19]将这个分布式参数模型应用到控制中，先求解该模型，再进行积分，然后转化成传递函数应用到控制中。

2. 机理建模

根据燃料电池系统的机理，按照物料平衡、能量平衡等方程

可以建立燃料电池的机理模型。Pukrushpan 等^[13]提出了燃料电池系统级的动态模型,将阴极和阳极的流体流动的动态特性加入到模型中。Pathapti 等^[20]提出了一个完整的系统级的燃料电池动态模型,同时考虑了动态特性的 3 个方面:燃料电池的温度变化、流道的流体流量变化及双层充电(charge double layers)的影响,并在 Simulink 中实现了该模型。Xue 等^[21]将燃料电池系统分成 3 个控制体,结合机理知识和经验模型,建立了一个系统级的动态模型^[22]。但这些模型都比较简单,没有将一些动态因素考虑在内,需要进一步研究。Hung 等^[23]用键合图(bond graph)方法来建立燃料电池的实时动态模型,考虑流体动态、热传输和电化学影响,建立了以阴极流体质量、阳极流体质量、阴极能量、阳极能量和电池体温度为状态变量的非线性模型,并将其线性化得到状态空间方程。这个方法简单易用,只是没有考虑辅助系统的模型。C. Kunusch^[24]基于系统辨识方法建立了燃料电池系统空间状态方程,该方法首先以电堆电流、阴极氧气流量为输入,电堆电压和阴极总压力为输出,通过实验数据建立它们两两之间的传递函数,再通过传递函数转换成状态空间方程,该方法建立起来的模型和实际相符,可用于燃料电池系统实时控制中,只是没有考虑湿度问题。

3. 数据建模

数据建模或辨识建模是常用的控制系统建模方法,对于难以建立机理模型的系统或建模成本很高的系统可采用该方法。在燃料电池系统建模中,有些文献用半经验模型甚至神经网络来描述燃料电池动态特性。Ogaji 等^[25]就提出用神经网络建模;A. Saengrung 等^[26]用反向传播(BP)神经网络和径向基(radial basis function)神经网络建立了燃料电池系统模型,该模型输入为空气流量和电堆温度,输出为电堆电压和电流,其预测算法的速度和精确性可以满足实时控制的要求。Li 等^[27]提出用最小二乘支持

向量机的方法建立模型。Rouss 等^[28]结合多层感知器神经网络和时间回归输入矢量建立了燃料电池系统多输入/多输出模型,分析的结果表明该方法能够对燃料电池系统进行准确的预测。数据建模的缺陷在于数据样本难以获得及数据点稀疏,这样建立的模型就难以泛化且易受噪声的影响。

2.2.4 几种商业化软件与模型

现在国外已经有一些燃料电池商业软件包^[29],主要有 Emmeskey, GCTool, ADVISOR 2002, Easy5, FEMLAB, Star-CD 等。Emmeskey^[30]是 0 维的燃料电池堆软件包,该模型基于 Simulink,它能在固定或不定的时间步运行,也可在实时模型上运行。该软件中的燃料电池堆是一个黑箱模型,对系统中质子交换膜的水传递、水的冷凝和蒸发、反应生成的热传递进行了详细建模。该模型的一个特点是包括压力动态。阴极和阳极的压力通过 PI 控制器来控制,通过调整冷却水的流量,PI 控制器可调节阴极出口的温度。因为有压力动态特性,该软件可以评价不同燃料电池系统控制策略。出于商业保密,关于燃料电池计算的详细信息难以得知。

ADVISOR 2002 软件用 MATLAB 和 Simulink 编写,包含两个模型。第一个模型简单地模拟燃料电池系统,将系统的效率特性作为系统净输出功率的函数。一个假设是:系统消耗一定量的燃料就可以提供特定的净功率,与系统的复杂性无关。第二个模型方法类似,但燃料电池的性能基于极化曲线、堆的单电池个数和单电池消耗的燃料。辅助系统(如压缩机、燃料泵和冷却风扇)和电池堆独立。ADVISOR 2002 模型的缺点是没有包括热量和水管理,燃料电池和汽车其他部分的热交换不能显示。

GCTool 是公开的软件包,用 C 语言编写。它包括各种不同类型的燃料电池和系统构件,如重整器、冷凝器、泵和喷嘴。用户可自定义不同组件的系统配置,可进行稳态和动态模拟。它有自

己的热力学特性库。Easy5 类似于 GCTool, 也有自己的组件库, 包括电池堆、重整器、气体清洁装置、电力装置和控制装置, 也包括系统的热和流体模型。它的一个特点是可进行系统优化和组件尺寸设计。但它没有自己的热力学特性库。FEMLAB 的化学工程模块中包括燃料电池模型, 用 MATLAB 代码编写。该模型是一个稳态、二维模型, 甚至包括单电池的三维模型, 它提供热传递和物质传递的详细模型。

VT 燃料电池系统模型^[31]由 Virginia 科技和美国国家可再生能源实验室 (NERL) 共同开发, 包括燃料电池模型和辅助系统模型, 它是一个动态、半经验模型, 描述了系统中的热管理和水平衡。它的燃料电池模型是一极化曲线, 压缩机采用 OpconAutorotor^[32]模型的目标是分析热起动和冷起动对车辆的燃料经济性 & 功率的影响。模型的输入参数为单电池的数量及活化面积、阴极和阳极流体的化学计量比系数、空气压缩机和泵的特性、单电池最小电压和电流密度、最大冷却温度。常数为开环电压, 以及空气和氢气的热容系数、摩尔分子数、密度。初始条件为环境的温度、水箱的温度、散热器的温度、阴极出口温度、压缩机出口温度、加湿器出口温度、冷却剂进口环境压力及冷却剂最小流率。系统输出为净功率和系统特征 (辅助部件的所需功率、电池内不同点的物质流量、热损失、水平衡、电池电流和电压)。

KTH 燃料电池系统模型^[33]是瑞典皇家科技研究所开发的半经验、稳态模型。该模型是在 Springer^[34]模型的基础上发展起来的, 考虑到了堆的设计, 可按给定的系统最大功率输出计算电池的数目。它有很大的灵活性, 适用于所有类型的燃料电池堆。辅助系统包括氢气罐、泵、风扇及压缩机。系统考虑到了氢气循环、堆中生成水和增湿器中水的冷凝, 堆中生成的热量由冷却循环系统排出。模型还考虑到了摩擦损失, 系统输出是净功率, 系统特征主要有反应气体的流量、惰性物质、冷却剂、堆中热传递、辅助装置的寄生功率、系统的水平衡、系统的效率等。

从以上对商业化软件中的模型和文献中的模型的分析来看, 这些模型对燃料电池辅助系统的分析和建模比较深入, 但对燃料电池堆的分析和建模相对比较简单(如将电堆看做黑箱, 用极化曲线代替电堆的性能等), 对燃料电池堆中的一些动态特性影响因素分析不够深入, 需要进一步完善。

以上对质子交换膜燃料电池各种系统级的模型和软件进行了综述, 并对各个子系统的模型(电压模型、空气供应、水管理和温度)做了总结。从国外研究情况来看, 单电池机理模型的研究相对较多, 研究也较成熟, 但电堆和系统级的模型及动态模型的研究相对较少, 正在发展之中。从各种建模方法来看, 机理模型过于复杂, 不适合用于控制中; 燃料电池堆的简化模型可用于控制中, 但简化模型一般是在一些假设条件下得出的, 这些假设往往是对燃料电池工作过程中的复杂机理的简化, 这些机理可能对电堆的性能有重要影响, 如电堆中的湿度和水传递过程对电堆性能有很大影响, 但简化模型中对此考虑较少。将机理模型和简化模型结合起来, 建立既符合燃料电池特性又相对简单的模型是以后研究的方向。

2.3 质子交换膜燃料电池机理模型

质子交换膜燃料电池机理模型是在一定假设的基础上, 运用基本守恒定律、传质传热方程和电化学反应方程, 结合电池内部的特征而获得的数学模型。质子交换膜燃料电池机理模型有多种, 包括三维、二维、一维及宏观模型。本节从控制系统角度出发, 建立质子交换膜燃料电池宏观模型。

2.3.1 燃料电池电压模型

燃料电池堆由许多单片燃料电池串联而成，电堆电压是各单片燃料电池电压之和。假设各个单片燃料电池是相同的，则电堆电压 V_{st} 可表示为单片燃料电池电压 V_{fc} 乘以电池片数 n ，即：

$$V_{st} = n \cdot V_{fc} \quad (2.1)$$

单片燃料电池电压 V_{fc} 是电堆电流、温度、湿度、阴极和阳极气体压力的函数。文献中有很多燃料电池电压模型，本书采用物理化学模型和经验模型相结合的方式来计算^[7]。

$$V_{fc} = E_0 - V_{act} - V_{ohm} - V_{conc} \quad (2.2)$$

式中， E_0 为开环电路电压， V_{act} 为活化损失电动势， V_{ohm} 为欧姆损失电动势， V_{conc} 为浓差损失电动势。

开环电路电压 E_0 根据反应气体和生成物之间的能量平衡、法拉第常数来计算^[35]。

$$E_0 = 1.229 - 0.85 \times 10^{-3} (T - 298.15) + 4.3085 \times 10^{-5} T \left[\ln(p_{H_2}) + 0.5 \ln(p_{O_2}) \right] \quad (2.3)$$

式中， T 是电堆温度， p_{H_2} 是氢气压力， p_{O_2} 是阴极进入的氧气压力。

活化损失电动势的产生是因为从阳极到阴极移动电子的过程中要消耗能量，活化损失在燃料电池的阴极和阳极都会发生，但是阳极的氢气氧化相当快，而阴极的反应要慢得多。因此由于活化损失造成的电压降主要由阴极反应条件决定，活化损失电动势和电流密度之间的关系为：

$$V_{act} = V_0 + V_a (1 - e^{-q_i}) \quad (2.4)$$

式中， V_0 是零电流密度条件下的电压降， V_a 和 q_i 是常数。

V_0 和 V_a 可用下式计算：

$$\begin{aligned}
 V_0 &= 0.279 - 8.5 \times 10^{-4} (T - 298.15) + \\
 &4.308 \times 10^{-5} T \left[\ln \left(\frac{p_{\text{ca}} - p_{\text{sat}}}{1.01325} \right) + \frac{1}{2} \ln \left(\frac{0.01173(p_{\text{ca}} - p_{\text{sat}})}{1.01325} \right) \right] \\
 V_a &= (-1.618 \times 10^{-5} T + 1.618 \times 10^{-2}) \left(\frac{p_{\text{O}_2}}{0.1173} + p_{\text{sat}} \right)^2 \\
 &+ (1.8 \times 10^{-4} T - 0.166) \left(\frac{p_{\text{O}_2}}{0.1173} + p_{\text{sat}} \right) \\
 &+ (-5.8 \times 10^{-4} T + 0.5736)
 \end{aligned}$$

i 是电流密度, 定义为电堆电流 I_{st} 和单片燃料电池有效面积 A_{fc} 的比值, 即:

$$i = \frac{I_{\text{st}}}{A_{\text{fc}}} \quad (2.5)$$

欧姆损失电动势的产生是由于传输质子时质子交换膜的阻力和传输电子时的阻力, 欧姆损失电动势和电流密度成正比, 即:

$$V_{\text{ohm}} = i \cdot R_{\text{ohm}} \quad (2.6)$$

式中, R_{ohm} 是燃料电池的欧姆内阻, 单位是 $\Omega \cdot \text{cm}^2$ 。内阻和膜的湿度及燃料电池的温度密切相关, 研究表明欧姆内阻是膜的传导率 σ_{m} 的函数, 即:

$$R_{\text{ohm}} = \frac{t_{\text{m}}}{\sigma_{\text{m}}} \quad (2.7)$$

式中, t_{m} 是膜的厚度。

膜的传导率 σ_{m} 可用下式计算:

$$\sigma_{\text{m}} = h_1 \exp(h_2 (1/303 - 1/T))$$

式中, h_2 是常数, h_1 是膜的水容量 λ_{m} 的函数。

$$h_1 = 0.005139 \lambda_{\text{m}} - 0.00326$$

当燃料电池发生电化学反应时, 反应物的浓度会下降, 这时会产生浓差损失电动势, 这也是高电流密度时电堆电压迅速下降

的原因。浓差损失电动势可由下式计算：

$$V_{\text{conc}} = i(c_2 i / i_{\text{max}})^{c_3} \quad (2.8)$$

式中， c_2 、 c_3 和 i_{max} 是常数，取决于电堆温度和反应物压力，可由实验测定。

2.3.2 阴极流道模型

阴极流道模型描述阴极中空气的流动特性，主要用质量守恒定律和空气的热动力学来描述。这里有几个假设：

(1) 所有的气体遵从理想气体定律。

(2) 阴极内的空气温度等于电堆中的温度。

(3) 流出阴极的流体特性和阴极内流体特性相同，如温度、压力和湿度。

(4) 当气体的湿度超过 100% 时，水蒸气凝结成液体，液态水不离开电堆，或者在阴极积聚，或者蒸发成气态。

(5) 多个单电池的流道和阴极的体积都集总为一个总的体积。

阴极中主要有 3 种气体成分：氧气、氮气和 water 蒸气。它们的质量平衡方程如下：

$$dm_{\text{O}_2} / dt = W_{\text{O}_2, \text{in}} - W_{\text{O}_2, \text{out}} - W_{\text{O}_2, \text{rec}} \quad (2.9)$$

$$dm_{\text{N}_2} / dt = W_{\text{N}_2, \text{in}} - W_{\text{N}_2, \text{out}} \quad (2.10)$$

$$dm_{\text{H}_2\text{O}, \text{ca}} / dt = W_{\text{v}, \text{ca}, \text{in}} - W_{\text{v}, \text{ca}, \text{out}} + W_{\text{v}, \text{gen}} + W_{\text{v}, \text{mbr}} + W_{\text{inj}} \quad (2.11)$$

式中， $W_{\text{O}_2, \text{in}}$ 为进入阴极空气中氧气的质量流率， $W_{\text{O}_2, \text{out}}$ 为流出阴极空气中氧气的质量流率， $W_{\text{O}_2, \text{rec}}$ 为反应消耗的氧气质量流率， $W_{\text{N}_2, \text{in}}$ 为进入阴极空气中氮气的质量流率， $W_{\text{N}_2, \text{out}}$ 为流出阴极空气中氮气的质量流率， $W_{\text{v}, \text{ca}, \text{in}}$ 为进入阴极空气中水蒸气的质量流率， $W_{\text{v}, \text{ca}, \text{out}}$ 为流出阴极空气中水蒸气的质量流率， $W_{\text{v}, \text{gen}}$ 为燃料电池中反应生成水的质量流率， $W_{\text{v}, \text{mbr}}$ 为穿过膜传输的水的质量流率， W_{inj}

为通过加湿方式进入阴极水的质量流率。

阴极中的水以两种形式存在：气态和液态。这取决于阴极气体的饱和状态，阴极中所能容纳的水蒸气最大质量可用饱和蒸汽压来计算：

$$m_{v,\max,ca} = \frac{p_{\text{sat}} V_{ca}}{R_v T_{\text{st}}} \quad (2.12)$$

如果阴极中水蒸气压力超过饱和蒸汽压，则凝结成液态水。阴极中的液态水和气态水由以下公式计算^[13]：

$$\begin{aligned} m_{w,ca} \leq m_{v,\max,ca} &\rightarrow m_{v,ca} = m_{w,ca}, \quad m_{l,ca} = 0 \\ m_{w,ca} > m_{v,\max,ca} &\rightarrow m_{v,ca} = m_{v,\max,ca}, \quad m_{l,ca} = m_{w,ca} - m_{v,\max,ca} \end{aligned} \quad (2.13)$$

阴极的压力为氧气分压、氮气分压和水蒸气分压之和，即：

$$P_{ca} = P_{O_2} + P_{N_2} + P_{v,ca} \quad (2.14)$$

根据气体混合物的热力学特性^[36]，有：

$$P_{O_2} = \frac{m_{O_2} R_{O_2} T_{\text{st}}}{V_{ca}} \quad (2.15)$$

$$P_{N_2} = \frac{m_{N_2} R_{N_2} T_{\text{st}}}{V_{ca}} \quad (2.16)$$

$$P_{v,ca} = \frac{m_{v,ca} R_v T_{\text{st}}}{V_{ca}} \quad (2.17)$$

进堆的氧气、氮气和水蒸气质量流率与进堆的空气流率 $W_{ca,in}$ 相关，即：

$$W_{O_2,in} = y_{O_2} / (1 + \mathbb{W}_{\text{atm}}) W_{ca,in} \quad (2.18)$$

$$W_{N_2,in} = y_{N_2} / (1 + \mathbb{W}_{\text{atm}}) W_{ca,in} \quad (2.19)$$

$$W_{v,ca,in} = \mathbb{W}_{\text{atm}} / (1 + \mathbb{W}_{\text{atm}}) W_{ca,in} \quad (2.20)$$

y_{O_2} 和 y_{N_2} 分别为干空气中氧气和氮气的质量含量，如下：

$$y_{O_2} = x_{O_2} \frac{M_{O_2}}{M_a^{\text{atm}}} \quad (2.21)$$

$$Y_{N_2} = (1 - x_{O_2}) \frac{M_{N_2}}{M_a^{\text{atm}}} \quad (2.22)$$

式中, x_{O_2} 为大气中氧气的体积含量, 其值一般为 0.21。

$$M_a^{\text{atm}} = x_{O_2} M_{O_2} + (1 - x_{O_2}) M_{N_2} \quad (2.23)$$

阴极进口的湿度比值为:

$$W_{\text{atm}} = \frac{M_v}{M_a} \frac{\phi_{\text{atm}} P_{\text{sat}}^{\text{atm}}}{P_{\text{atm}} - \phi_{\text{atm}} P_{\text{sat}}^{\text{atm}}} \quad (2.24)$$

阴极出口各组分流量的由以下公式计算:

$$W_{O_2, \text{out}} = \frac{m_{O_2}}{m_{\text{ca}}} W_{\text{ca}} \quad (2.25)$$

$$W_{N_2, \text{out}} = \frac{m_{N_2}}{m_{\text{ca}}} W_{\text{ca}} \quad (2.26)$$

$$W_{v, \text{ca}, \text{out}} = \frac{p_{v, \text{ca}} V_{\text{ca}} M_v}{RT_{\text{st}} m_{\text{ca}}} W_{\text{ca}} \quad (2.27)$$

式中, $m_{\text{ca}} = m_{O_2} + m_{N_2} + \frac{p_{v, \text{ca}} V_{\text{ca}} M_v}{RT_{\text{st}}}$ 是阴极气体的总质量。

反应所消耗的氧气流量 $W_{O_2, \text{ret}}$ 和生成水的流量 $W_{v, \text{gen}}$ 由下式计算:

$$W_{O_2, \text{ret}} = M_{O_2} (nI_{\text{st}}) / (4F) \quad (2.28)$$

$$W_{v, \text{gen}} = M_{H_2O} (nI_{\text{st}}) / (2F) \quad (2.29)$$

2.3.3 阳极流道模型

和阴极流道模型相同, 阳极中气体成分主要是氢气和水蒸气, 它们的质量平衡方程如下:

$$\frac{dm_{H_2}}{dt} = W_{H_2, \text{in}} - W_{H_2, \text{out}} - W_{H_2, \text{rec}} \quad (2.30)$$

$$\frac{dm_{v,an}}{dt} = W_{v,an,in} - W_{v,an,out} - W_{v,mbr} \quad (2.31)$$

式中, $W_{H_2,in}$ 为进入阳极的氢气质量流率, $W_{H_2,out}$ 为流出阳极的氢气质量流率, $W_{H_2,rec}$ 为燃料电池反应消耗的氢气质量流率, $W_{v,an,in}$ 为进入阳极的水蒸气质量流率, $W_{v,an,out}$ 为流出阳极的水蒸气质量流率, $W_{v,mbr}$ 为穿过膜传输的水的质量流率。

进堆氢气的净流量和水蒸气的流量与进入阳极的气体流量 $W_{an,in}$ 相关, 即:

$$W_{H_2,in} = (1 - \alpha) W_{an,in} \quad (2.32)$$

$$W_{v,an,in} = \alpha W_{an,in} \quad (2.33)$$

式中, α 为进堆氢气的水蒸气含量。

出堆气体总流量采用文献[13]公式计算:

$$W_{an,out} = k_{an,out} (P_{an} - P_{rm,an}) \quad (2.34)$$

式中, P_{an} 为阳极的压力; $P_{rm,an}$ 为氢气回流管道压力, 约等于大气压。

出堆氢气和水蒸气的流量用以下公式计算:

$$W_{H_2,an,out} = \frac{1}{1 + \omega_{an,out}} W_{an,out} \quad (2.35)$$

$$W_{v,an,out} = \frac{\omega_{an,out}}{1 + \omega_{an,out}} W_{an,out} \quad (2.36)$$

$$\omega_{an,out} = \frac{M_v}{M_{H_2}} \cdot \frac{m_{H_2} R_{H_2}}{m_{v,an} R_{H_2}} \quad (2.37)$$

$W_{v,mbr}$ 由膜的水传递公式计算, 反应消耗的氢气流量 $W_{H_2,rec}$ 是电流的函数

$$W_{H_2,rec} = M_{H_2} (nI_{st}) / (2F) \quad (2.38)$$

2.3.4 燃料电池质子交换膜水模型

质子交换膜燃料电池中的水包括气态和液态两种，其来源包括由电化学反应生成的水（阴极）和反应气体加湿代入的水。通过对燃料电池工作原理的分析可知，燃料电池反应生成的水是在阴极由氢离子和氧气在催化剂的作用下生成的。对反应气体进行加湿是为了使质子交换膜始终保持最佳的湿润状态，从而使电池稳定运行^[37]。水过多或过少都会对质子交换膜燃料电池带来负面影响，主要表现在以下几个方面。

（1）燃料电池内水过多，则会凝聚成液态水珠，导致传质过程受阻，降低氧气通过气体扩散层的速度，甚至会淹没电催化剂的活性点。

（2）液态水的存在导致气体在电极内和系统内各单元之间分布不均匀，这将使电池性能下降，并造成系统内各个单元电池的电压不等。

（3）反应气体被水蒸气稀释，从而造成反应界面上反应气体的不足。

（4）如果质子交换膜失水过多，其电导率将会下降，导致电池的欧姆压降增大。

（5）质子交换膜中的含水量对电催化活性也有影响，当膜失水后，催化层界面的活性也会下降。

燃料电池的很多运行参数和结构参数都影响交换膜的含水量，下面具体讨论各种参数对含水量的影响。为了便于观察和比较，每次测试只改变其中某一个参数，其他参数均保持不变，将测试的结果进行计算比较，分析该参数对交换膜含水量的影响。如果没有提及某参数的变化，则所用的固定参数为：电流密度 $0.6\text{A}/\text{cm}^2$ ；阴极加湿温度 50°C ；阳极加湿温度 70°C ；电堆运行温度 70°C ；孔隙率 0.5（单位为标量 1）。

1. 电流密度

在不同电流密度条件下,膜中从阴极到阳极的含水量如图 2.3 所示。其中,横轴表示的是交换膜从阴极到阳极的坐标位置,纵轴表示的是交换膜同一厚度处的平均含水量。从图中可以看出,在其他条件相同时,在较小的电流密度下,膜中的水分布接近一条直线。随着电流密度的增大,膜中的含水量呈指数衰减。电迁移水量随着电流密度增大而增加,使电池阳极侧的含水量下降,从而导致膜中的整个含水量曲线都下移。同时,随着膜中的水浓度下降,电迁移水量也将降低,膜中的水迁移重新达到平衡。沿质子交换膜厚度方向,膜中含水量按指数规律降低,且电流密度越大,膜中含水量下降越快,降低幅度越大。




图 2.3 不同电流密度下的膜中含水量

在改变电流密度时,质子交换膜中平均含水量与电流密度的关系曲线如图 2.4 所示。从图中可以看出,当电流密度从 $0.03\text{A}/\text{cm}^2$ 增加到 $0.25\text{A}/\text{cm}^2$ 时,膜中含水量迅速增加。因为当电流密度较小时,燃料电池阴极侧质子交换膜基本上处于干燥状态(生成水较少),随着电流密度的增加,电迁移从阳极带入阴极的水和阴极电化学反应生成的水使燃料电池阴极迅速润湿,所以膜中含水量也

迅速增加。当电流密度进一步增加时，交换膜中的含水量不再继续上升，反而下降了，这是因为当电流密度达到一定值后再增大时，质子交换膜阴极侧含水量就接近饱和了，而阳极由于电拖使更多的水从阳极迁移到阴极，同时通过浓差扩散的水扩散速度太慢，不足以补充阳极的失水，所以阳极侧含水量下降，这就导致了整个膜中平均含水量的下降。当电流密度达到一定值后，膜中含水量还有所上升，这是由于此时阴极侧生成的液态水饱和度上升，而膜吸收液态水的能力较强，所以质子交换膜中平均含水量有所增加。




图 2.4 质子交换膜中平均含水量与电流密度的关系曲线

2. 阴极加湿温度

在膜中含水量总是阴极高于阳极，并且从阴极到阳极逐渐降低。因为当电流密度为 0.6 A/cm^2 时，不管阴极加湿或者不加湿，此时电迁移从阳极代入阴极的水加上阴极电化学反应生成的水，使阴极侧膜处于接近饱和的状态，而阳极侧在该电流密度下电拖带走的水量较大，所以膜阴极侧含水量比阳极侧含水量高，阳极气体中的含水量下降较快。

如图 2.5 所示是在三种不同阴极加湿条件下质子交换膜中的含水量，加湿温度与加湿量存在正向关系。从图中可以看出，随

随着阴极加湿温度的提高，质子交换膜阴极侧膜中含水量有一定增加，但是增幅不大，这是因为在该运行电流密度下，阴极侧膜中含水量基本已经接近饱和了。有一定增加是因为随着阴极加湿量的增加，阴极侧水的液态饱和度增加，而膜吸收液态水的能力较强。阳极侧质子交换膜中含水量基本上保持不变，这是因为在相同的运行条件下，从阴极侧扩散到阳极侧的水量与相同运行条件下由电迁移从阳极带到阴极的水量相近，故质子交换膜阳极侧含水量变化不大。




图 2.5 不同阴极加湿条件下质子交换膜中的含水量

3. 阳极加湿温度

如图 2.6 所示是在三种不同阳极加湿条件下的膜中含水量。已知加湿量与加湿温度存在正向关系。从图中可以看出，随着阳极加湿温度的降低，质子交换膜阳极侧含水量迅速下降，而阴极侧含水量变化不大，这是因为在该运行条件下，膜阴极侧已经接近饱和，而从流道到阳极侧质子交换膜的水浓度梯度随加湿温度的降低而减小，这样就导致从流道扩散到质子交换膜阳极侧的水

量减小，所以质子交换膜阳极侧含水量降低。当阳极不加湿时，膜中含水量基本上靠阴极电迁移和反扩散带来的水维持。而在此条件下，阴极和阳极两侧含水量分别接近了饱和值和最小值，两侧的水浓度梯度基本上达到最大，电迁移和反扩散水量最大。




图 2.6 不同阳极加湿条件下的膜中含水量

表 2.1 是膜中含水量与加湿温度关系表。从表中可以看出，在阳极加湿温度保持 70℃ 不变的情况下，阴极加湿条件从不加湿到 50℃ 加湿、70℃ 加湿时，质子交换膜中含水量有一定增加，但是增加量较小。在阴极加湿温度保持 70℃ 不变的情况下，阳极加湿条件从不加湿到 50℃ 加湿、70℃ 加湿时，膜中含水量却增加较多。当阳极和阴极都不加湿时，膜中含水量只有 7.36，这样膜就相对较干燥，质子交换膜电阻就较大。

表2.1 膜中含水量与加湿温度关系表

加湿	阳极加湿温度℃	0	50	70	70	70	0
	阴极加湿温度℃	70	70	70	50	0	0
含水量		8.46	8.68	9.85	9.56	9.38	7.36

4. 电堆运行温度

如图 2.7 所示是三种不同运行温度下从阴极到阳极的膜中含水量。从图中可以看出，在其他运行条件相同的情况下，质子交换膜阴极侧的含水量随燃料电池运行温度的降低而升高。这是由于电池运行温度较低时，水的饱和蒸气压下降，这就导致更多的水蒸气冷凝成液态水，阴极侧液态饱和度升高，而质子交换膜吸收液态水的能力比吸收气态水的能力强，所以阴极侧膜中含水量随运行温度的下降而升高。阳极侧膜中含水量随燃料电池运行温度的降低也有所升高，但是升高量不大，这是由于阴极侧膜中含水量升高时，阴极和阳极两侧水的浓度梯度升高，导致从阴极到阳极的水反扩散量增加。阴极侧由于电迁移带入的水和电化学反应生成的水较多，所以膜阴极侧含水量比阳极侧高。




图 2.7 不同运行温度下从阴极到阳极的膜中含水量

5. 扩散层孔隙率

如图 2.8 所示是在两种不同扩散层孔隙率下的质子交换膜中含水量。从图中可以看出，当扩散层孔隙率减小时，质子交换膜

阴极侧膜中含水量升高，阳极侧膜中含水量降低。这是因为在孔隙率变小时，水在扩散层中的传递阻力增大，在阳极从流道到质子交换膜的水浓度梯度变大，而在流道气体中含水量一定的情况下，阳极侧膜中含水量就会随梯度下降；在阴极由于反应产生的水及电迁移代入的水通过气体扩散层排出难度加大，这样就导致阴极侧膜中含水量升高，从而使膜两侧水浓度梯度增大，水的反扩散量增加，当反扩散量和电迁移以及电化学反应生成的水达到新的平衡时，燃料电池就又运行在一个新的稳定点。




图 2.8 不同扩散层孔隙率下的膜中含水量

6. 膜两侧气体的压力差

从图 2.9 可以看出，膜两侧压力差对质子交换膜中含水量分布有一定的影响。沿质子交换膜厚度方向，膜中含水量由压力低侧向压力高侧按指数规律降低，且压力差越大，膜中单位厚度含水量越低，含水量梯度下降越大。这是因为膜两侧存在的压力差导致膜内也存在压力差梯度，在压力迁移作用下，导致水从压力高侧向压力低侧迁移，压力差越大，压力迁移量也就越大。

燃料电池系统质子交换膜水模型相对比较复杂，本节建立适合于控制的经验模型，主要考虑膜中水传递过程，对膜中水分布情况也适当考虑。




图 2.9 膜中含水量分布随膜两侧压力差变化规律 ($T=70^{\circ}\text{C}$)

膜中水传递过程主要包括电迁移和浓差扩散两种机制^[37]。首先，电迁移现象是质子携带水分子从阳极穿过膜到达阴极所引起的，水的流量正比于电迁移系数 n_d ，PEMFC 在工作过程中，在阳极形成的氢离子将越过膜来到阴极，由于质子都处于水合状态，当质子进行迁移时，在电渗力的作用下必然将部分水带至阴极，越过膜的质子数越多（电流密度越大），每个质子携带的水分子也越多（电渗系数越大），则随同质子从阳极迁移至阴极的水也越多。其次，浓差扩散现象是由阴极和阳极之间的浓度差所引起的扩散现象，由于电渗作用，膜的阳极侧水将减少，同时由于阴极区有电极反应生成的水，造成水在膜两侧形成浓度差，从而产生水由阴极向阳极的扩散，扩散的速度正比于浓度梯度^[40]。

电迁移作用和浓差扩散作用分别使水向相反的方向运动，如果两者的速率相等，膜中的水仍处于平衡状态。然而在实际的工

作状态下，随着放电电流的增加，反向扩散水量越来越低于正向电渗迁移的水量，形成所谓的水净迁移，即总结果是水从膜的阳极侧迁移至阴极侧，导致膜的阳极侧脱水。为了建立新的水平衡，必须设法补充水，并且使阳极侧补充的水量等于净的水迁移量。在这种新的平衡状态下，凡是影响电渗、扩散、水补充的因素都会影响水的平衡。例如，放电电流密度既影响水的生成量，又影响电渗；电池工作温度会影响水在气室的饱和蒸气压，进而影响扩散和水的补充；反应气的湿化程度会影响扩散及水的补充等。另外，在水的补充和排水过程中，可能出现水的蒸发和冷凝，相变的潜热还会影响到电池的热传递和工作温度。一般说来，较小的电流密度、较大的反应气流速、较低的湿度、较高的温度、较低的压力会导致水的缺乏；反之，则会导致水的过剩。如果生成水与进入电池内的水之和小于电池的排水量，则膜将脱水，使电池电阻增大，电压降低，进而影响电池的使用寿命；如果生成水与进入电池内的水之和大于排水量，则阴极可能被淹，影响气体扩散，同样也会使电池性能降低，甚至使电池无法正常工作。要使电池具有良好的性能，必须设法使膜始终保持湿润状态而阴极又不被淹渍，维持电池内的水平衡。

综合两种水传递机制，从阳极到阴极穿过膜的水流量为：

$$W_{v,mem} = M_v A_c n \left(\frac{n_d I_{st}}{F} - D_w \frac{c_{v,ca} - c_{v,an}}{t_m} \right) \quad (2.39)$$

系数 n_d 和 D_w 随着膜中水含量 λ_m 的改变而改变^[38]，它们的表达式分别为：

$$n_d = 0.0029 \lambda_m^2 + 0.05 \lambda_m - 3.4 \times 10^{-19} \quad (2.40)$$

$$D_w = D_\lambda \exp \left(2416 \left(\frac{1}{303} - \frac{1}{T_{st}} \right) \right) \quad (2.41)$$

其中，

$$D_{\lambda} = \begin{cases} 10^{-6}, & \lambda_m < 2 \\ [1 + 2(\lambda_m - 2)] \times 10^{-6}, & 2 \leq \lambda_m \leq 3 \\ [3 - 1.67(\lambda_m - 3)] \times 10^{-6}, & 3 < \lambda_m < 4.5 \\ 1.25 \times 10^{-6}, & \lambda_m \geq 4.5 \end{cases} \quad (2.42)$$

式中, λ_m 是膜中平均含水量, 由下式计算^[38]:

$$\lambda_m = \begin{cases} 0.043 + 17.81a_m - 39.85a_m^2 + 36.0a_m^3, & 0 < a_m \leq 1 \\ 14 + 1.4(a_m - 1), & 1 < a_m \leq 3 \end{cases} \quad (2.43)$$

a_m 是阳极和阴极的水活度的平均值, 即:

$$a_m = \frac{a_{an} + a_{ca}}{2} \quad (2.44)$$

$$a_{an} = \frac{P_{v,an}}{P_{sat,an}}$$

$$a_{ca} = \frac{P_{v,ca}}{P_{sat,ca}}$$

考虑水的电迁移和扩散的影响, 质子交换膜中水传递方程可写为^[12]:

$$\frac{\partial c}{\partial t} = -\frac{\partial J}{\partial x} = \frac{\partial}{\partial x} \left(D \frac{\partial c}{\partial x} - \frac{i}{F} w \right) \quad (2.45)$$

式中, J 是穿过膜的水流量, 通过此方程, 可以计算出膜中随时间和膜厚度变化的水浓度。

为了解此方程, 假设膜中的初始水浓度为:

$$\alpha(x, 0) = c_0(x) \quad (0 < x < d), \quad t = 0 \quad (2.46)$$

式中, $c_0(x)$ 为时间 $t=0$, 对应的初始电流为 i_0 时的水浓度。

此外, 膜有两个物理边界, $x=0$ 和 $x=d$, 在这两个物理边界上应该满足水流的连续性。

当 $x=0$ 时,

$$\frac{\beta_1 i}{F} + k[c_a - \alpha(0, t)] = -D \frac{\partial \alpha(0, t)}{\partial x} + \frac{w i}{F} \quad (2.47)$$

式中, k 是湿度参数^[39], c_a 是阳极的水浓度, β_1 是阳极渗入膜中的水的系数。

当 $x=d$ 时,

$$\frac{\beta_2 i}{F} + K[c_c - \alpha(d, t)] = D \frac{\partial \alpha(d, t)}{\partial x} - \frac{wi}{F} \quad (2.48)$$

式中, c_c 是阴极的水浓度, β_2 是阴极渗入膜中的水的系数。

2.3.5 燃料电池温度模型

质子交换膜燃料电池属于低温型电池, 其工作温度应维持在 $80 \sim 100^\circ\text{C}$ 之间, 否则各种极化都将增强, 造成电池性能恶化。为此, 进入燃料电池内部的反应气体一般都要进行预热, 该过程往往与加湿过程同步进行。另外, PEMFC 中有 $40\% \sim 50\%$ 的能量是以热能形式散发出去的, 因此当燃料电池正常工作时需要采取合适的方式对燃料电池进行冷却。因此利用燃料电池堆内的能量平衡和物质平衡方程, 建立燃料电池的温度模型是十分必要的。电堆内的能量平衡可以用下式表示:

$$q_{\text{theo}} = q_{\text{elec}} + q_{\text{sens}} + q_{\text{latent}} + q_{\text{cool}} \quad (2.49)$$

式中, q_{theo} 为理论上燃料电池反应产生的能量, q_{elec} 为燃料电池堆产生的电能, q_{sens} 为燃料电池堆中流体的温度转化成标准温度的能量, q_{latent} 为燃料电池阴极和阳极中的水蒸发或冷凝时产生的能量, q_{cool} 为通过冷却水带走的热量。

理论上燃料电池氢气和氧气反应产生的能量 q_{theo} 是氢气反应时的焓变和消耗氢气摩尔流量的乘积, 即:

$$q_{\text{theo}} = N_{\text{H}_2, \text{cons}} \Delta H_{\text{rxn}} \quad (2.50)$$

N_i 和 W_i (i 为氢气、氧气、氮气、水蒸气或液态水) 之间的换算关系为 N_i 等于 W_i 除以 i 的摩尔质量 (单位为 kg/mol), 即:

$$N_i = W_i / M_i \quad (2.51)$$

燃料电池堆产生的电能 q_{elec} 是单片燃料电池电压 V_{fc} 、电堆电流 I 和燃料电池片数 n 的乘积，即：

$$q_{\text{elec}} = nV_{\text{fc}}I \quad (2.52)$$

实际系统中，反应物的温度是变化的，在计算各种能量时，必须对反应物的温度进行等效处理，计算出各种流体（包括氢气、液态水、气态水）的温度转化成标准温度时释放或吸收的能量，阳极中各种流体温度转化的能量 $q_{\text{sens,a}}$ 为^[35]：

$$q_{\text{sens,a}} = \left(N_{\text{H}_2,\text{out}} C_{\text{p,H}_2,\text{g}} + N_{\text{w,g,a,out}} C_{\text{p,H}_2\text{O,g}} + N_{\text{w,l,a,out}} C_{\text{p,H}_2\text{O,l}} \right) (T_{\text{a,out}} - T_0) - \left(N_{\text{H}_2,\text{in}} C_{\text{p,H}_2,\text{g}} + N_{\text{w,g,a,in}} C_{\text{p,H}_2\text{O,g}} + N_{\text{w,l,a,in}} C_{\text{p,w,l,out}} \right) (T_{\text{a,in}} - T_0) \quad (2.53)$$

阴极中各种流体温度转化为标准温度的能量 $q_{\text{sens,c}}$ 为：

$$q_{\text{sens,c}} = \left(N_{\text{O}_2,\text{out}} C_{\text{p,O}_2,\text{g}} + N_{\text{w,g,c,out}} C_{\text{p,H}_2\text{O,g}} + N_{\text{w,l,c,out}} C_{\text{p,H}_2\text{O,l}} \right) (T_{\text{c,out}} - T_0) - \left(N_{\text{O}_2,\text{in}} C_{\text{p,O}_2,\text{g}} + N_{\text{w,g,c,in}} C_{\text{p,H}_2\text{O,g}} + N_{\text{w,l,c,in}} C_{\text{p,H}_2\text{O,l}} + N_{\text{N}_2,\text{in}} C_{\text{p,N}_2,\text{g}} \right) (T_{\text{a,in}} - T_0) \quad (2.54)$$

冷却水的温度转化为标准温度的能量 $q_{\text{sens,cool}}$ 为：

$$q_{\text{sens,cool}} = N_{\text{w,in}} C_{\text{p,w,l}} (T_{\text{w,out}} - T_{\text{w,in}}) \quad (2.55)$$

阳极中水蒸发产生的焓变能可用下式计算：

$$q_{\text{latent,a}} = (N_{\text{w,g,a,out}} - N_{\text{w,g,a,in}} + N_{\text{mem}}) H_{\text{vaporization}} \quad (2.56)$$

计算阴极的焓变能要稍微复杂一些，因为阴极有水生成和水的相变（液态和气态的互变），如果阴极中的液态水质量 $m_{\text{l,ca}} > 0$ ，即阴极中水蒸气已经达到了饱和状态，则有

$$q_{\text{latent,c}} = (N_{\text{w,g,c,out}} - N_{\text{mem}} - N_{\text{w,g,c,in}}) H_{\text{vaporization,c,l}} \quad (2.57)$$

否则，从入口带进来的液态水就会被蒸发，燃料电池反应生成的水也要被蒸发，则有：

$$q_{\text{latent},c} = N_{w,l,c,\text{in}} H_{\text{vaporization},c1} + (N_{w,g,c,\text{out}} - N_{\text{mem}} - N_{w,g,c,\text{in}} - N_{w,l,c,\text{in}}) H_{\text{vaporization},c2} \quad (2.58)$$

其中,

$$H_{\text{vaporization}} = 45070 - 41.9T + 3.44 \times 10^{-3} T^2 + 2.54 \times 10^{-6} T^3 - 8.98 \times 10^{-10} T^4 \quad (2.59)$$

下标 $c1$ 和 $c2$ 代表不同的状态,即不同的温度 T ,在 $H_{\text{vaporization},c1}$ 中 T 取环境的温度,在 $H_{\text{vaporization},c2}$ 中 T 取燃料电池堆的温度 T_{st} 。

这样燃料电池堆中流体的温度转化成标准温度的能量 q_{sens} 为:

$$q_{\text{sens}} = q_{\text{sens},a} + q_{\text{sens},c} + q_{\text{sens},\text{cool}} \quad (2.60)$$

燃料电池阴极和阳极中的水蒸发或冷凝时产生的能量 q_{latent} 为:

$$q_{\text{latent}} = q_{\text{latent},a} + q_{\text{latent},c} \quad (2.61)$$

通过冷却水带走的热量 q_{cool} 可通过下式计算:

$$q_{\text{cool}} = N_{w,\text{in}} C_{p,w,l} (T_{\text{st}} - T_{w,\text{in}}) \quad (2.62)$$

如果忽略通过燃料电池表面散发的热量,电堆温度 T_{st} 的动态方程可表示如下:

$$m_{\text{st}} C_{p,\text{st}} \frac{dT_{\text{st}}}{dt} = q_{\text{theo}} - q_{\text{elec}} - q_{\text{sens}} - q_{\text{latent}} - q_{\text{cool}} \quad (2.63)$$

式中, m_{st} 为燃料电池电堆的质量, $C_{p,\text{st}}$ 为燃料电池电堆的平均比热容 (average specific heat capacity), 在文献[35]中 Ballard Mark 5 号堆的 $m_{\text{st}} C_{p,\text{st}}$ 为 35kJ/K。

2.3.6 辅助设备模型

辅助设备是燃料电池系统必要的组成部分,主要包括风机、加湿器、冷却风扇等。这些辅助设备的性能对整个燃料电池系统也有很大影响,下面分别建立各辅助设备的模型。

1. 风机模型

风机的转速变化模型^[13]为

$$J_{bl} \frac{d\omega}{dt} = \tau_{cm} - \tau_{bl} \quad (2.64)$$

式中, J_{bl} 为风机的转动惯量, τ_{cm} 为风机电机的力矩, τ_{bl} 为风机负载的力矩。

τ_{cm} 用下式计算:

$$\tau_{cm} = \eta_{cm} \frac{k_t}{R_{cm}} (v_{cm} - k_v \omega) \quad (2.65)$$

式中, k_t , R_{cm} 和 k_v 是电动机常数, η_{cm} 是电动机机械效率, v_{cm} 为电机的控制电压。

风机负载的力矩 τ_{bl} 用下式计算:

$$\tau_{bl} = \frac{C_p T_{atm}}{\omega \eta_{bl}} \left[\left(\frac{p_{sm}}{p_{atm}} \right)^{\frac{\gamma-1}{\gamma}} - 1 \right] W_{bl} \quad (2.66)$$

式中, γ 是空气的热比率系数 (1.4), C_p 是空气的热容常压系数 $[1004 \text{ J}/(\text{kg} \cdot \text{K})]$, η_{bl} 是风机效率, p_{sm} 是供应管腔的压力, p_{atm} 和 T_{atm} 分别是大气压力和温度。

本节选用 HB-529D 2.6kW 风机, 风机的风量 W_{bl} 由转速和压力决定。由于神经网络有较好的函数逼近和泛化能力, 在此采用神经网络方法建立风机转速、压力和风量的关系。神经网络的结构为: 输入层有 2 个节点, 隐层有 10 个节点, 输出层有 1 个节点。神经网络的输入为压力和转速, 输出为风量, 神经网络的学习算法采用 BP 算法, 学习数据来自风机的测试数据, 表 2.2 列出了测试所得的部分数据。

表2.2 风机测试部分数据

喷嘴差压 (mmAq)	转速 (rpm)	风量 (cmm)	喷嘴差压 (mmAq)	转速 (rpm)	风量 (cmm)
194.06	2979	4.796	191.96	3559	5.829
270.41	2978	4.521	292.36	3559	5.693
299.72	2967	4.267	386.1	3555	5.541
588.78	2967	4.11	481.86	3551	5.374
789.51	2957	3.79	751.28	3537	5.266
951.07	2953	3.495	685.59	3534	5.068
1193.86	2942	3.234	763.82	3525	4.919
1390.82	2934	2.971	889.87	3525	4.704
1593.76	2928	2.72	977.95	3517	4.645
1793.33	2921	2.427	1186.47	3512	4.409
1996.12	2913	2.155	1377.6	3503	4.143
2196.92	2903	1.912	1592.71	3491	3.846
1960.14	3458	3.36	1788.94	3474	3.613

神经网络学习好以后，用 MATLAB 中的函数 gensim() 生成神经网络的仿真模块，加入到 Simulink 中。

2. 氢气循环泵模型

氢气循环泵将阳极中未反应完的氢气抽到氢气的进口管道中，使阳极中氢气循环，反应能力提高。氢气循环泵的流速和它的转速密切相关，而转速又和电流密切相关，氢气循环泵的状态空间方程可表示为：

$$\frac{d\omega_{HP}}{dt} = -\frac{k_{t,HP}}{J_{HP}}\omega_{HP} + \frac{k_{t,HP}}{J_{HP}}i_{HP} \quad (2.67)$$

$$\dot{m}_{H_2} = k_{m,HP}\omega_{HP}$$

式中, ω_{HP} 为氢气循环泵的转速, i_{HP} 为氢气循环泵的电, \dot{m}_{H_2} 为氢气的流速; J_{HP} 为氢气循环泵的转动惯量, $k_{\text{t,HP}}$, $k_{\text{l,HP}}$ 和 $k_{\text{m,HP}}$ 都为系数, 和氢气循环泵的结构相关。

3. 加湿器模型

为了保持燃料电池内的湿度, 提高燃料电池系统的发电效率, 氢气和空气进入电堆之前一般要加湿, 加湿的方法一般有对阳极加湿、对阴极加湿, 以及同时对阴极和阳极加湿。本书中采取阴极加湿, 主要理由是: 现在的质子交换膜越来越薄, 水可以很容易地从阴极渗透到阳极; 在燃料电池系统中空间狭小, 阴极加湿容易实现。阴极加湿的方法有很多, 如膜加湿器法、直接喷射法等。假设进入加湿器的空气流量为 W_{sm} , 进入加湿器的水蒸气压力等于空气相对湿度乘以饱和蒸气压, 即:

$$p_{\text{v,sm}} = \phi_{\text{sm}} p_{\text{sat}}(T_{\text{sm}}) \quad (2.68)$$

则进入加湿器的干空气压力等于空气压力减水蒸气压力, 即:

$$p_{\text{a,sm}} = p_{\text{sm}} - p_{\text{v,sm}} \quad (2.69)$$

湿度率可用下式计算:

$$\omega_{\text{sm}} = \frac{M_{\text{v}}}{M_{\text{a}}} \frac{p_{\text{v,sm}}}{p_{\text{a,sm}}} \quad (2.70)$$

则干空气流量和水蒸气流量分别为:

$$W_{\text{a,sm}} = \frac{1}{(1 + \omega_{\text{sm}})} W_{\text{sm}} \quad (2.71)$$

$$W_{\text{v,sm}} = W_{\text{sm}} - W_{\text{a,sm}} \quad (2.72)$$

离开加湿器的水蒸气则等于已有空气中水蒸气流量加加湿器增加的水蒸气流量, 即:

$$W_{\text{v,hm}} = W_{\text{v,sm}} + W_{\text{inj}} \quad (2.73)$$

W_{inj} 为加湿器加湿的水流量, 并假设以水蒸气的形式进入电堆。

则离开加湿器的空气相对湿度为:

$$\phi_{\text{hm}} = \frac{p_{\text{v,hm}}}{p_{\text{sat}} T_{\text{hm}}} \quad (2.74)$$

加湿器中水蒸气压力可以根据 $p = \frac{mRT}{V}$ 进行计算。

4. 水循环泵模型

水循环泵提供压力，使冷却水系统中的水以一定的流量和压力流动，从而将燃料电池电堆内产生的热量排出。为了描述水循环泵的动态行为，可以借鉴压缩机的工作原理，写出水循环泵的状态空间方程。

$$\begin{bmatrix} \frac{di_{\text{wp}}}{dt} \\ \frac{d\omega_{\text{wp}}}{dt} \end{bmatrix} = \begin{bmatrix} -\frac{R_{\text{wp}}}{L_{\text{wp}}} & -\frac{k_{\text{t,wp}}}{L_{\text{wp}}} \\ \frac{k_{\text{t,wp}}}{J_{\text{wp}}} & -\frac{k_{\text{f,wp}}}{J_{\text{wp}}} \end{bmatrix} \begin{bmatrix} i_{\text{wp}} \\ \omega_{\text{wp}} \end{bmatrix} + \begin{bmatrix} \frac{1}{L_{\text{wp}}} \end{bmatrix} V_{\text{wp}} \quad (2.75)$$

$$\dot{\mathbf{m}}_{\text{wp}} = \begin{bmatrix} 0 & k_{\text{m,wp}} \end{bmatrix} \begin{bmatrix} i_{\text{wp}} \\ \omega_{\text{wp}} \end{bmatrix}$$

式中， ω_{wp} 为水循环泵的转速， i_{wp} 为水循环泵的电流， V_{wp} 为水循环泵的控制电压，其他参数为和水循环泵相关的系数。

因为水循环泵的电气时间常数约为 0.005 秒，机械时间常数约为 0.5 秒，大大低于冷却水系统的时间常数，因此水循环泵的状态空间模型可用稳态时流量和控制电压的关系来描述，即：

$$\dot{\mathbf{m}}_{\text{wp}} = \frac{k_{\text{t,wp}} \frac{V_{\text{wp}}}{R_{\text{wp}}}}{k_{\text{m,wp}} \left(k_{\text{f,wp}} + \frac{k_{\text{t,wp}}^2}{R_{\text{wp}}} \right)} = k_{\text{wp}} V_{\text{wp}} \quad (2.76)$$

5. 水箱模型

水箱是冷却系统中储存水的容器。为了使燃料电池在环境温

度较低时也能快速起动，一般在水箱中加一个加热器，加热器所提供的热量可由用户设定，可记为 \dot{Q}_{heat} 。因为水箱中装的是水，有较大的热惰性，所以可以借用前面温度系统建模的公式，即：

$$\frac{dT_{\text{RV}}}{dt} = \frac{1}{m_{\text{RV}} c_{\text{p,RV}}} \left[\dot{Q}_{\text{heat}} + \dot{m}_{\text{CL}} \cdot c_{\text{p,CL}} (T_{\text{CL}} - T_{\text{RV}}) - k_{\text{RV}} (T_{\text{RV}} - T_{\text{amb}}) \right] \quad (2.77)$$

式中， T_{RV} 为水箱温度， m_{RV} 为水箱中水的质量， $c_{\text{p,RV}}$ 为水箱中水的比热容， \dot{m}_{CL} 为冷却水的流量， $c_{\text{p,CL}}$ 为冷却水的比热容， T_{CL} 为冷却水的温度， T_{amb} 为水箱外环境温度。

6. 热交换器模型

热交换器将燃料电池中产生的剩余热量排到大气中，它通过冷却风扇将冷却水中的热量散发到周围环境中。可以认为热交换器的热传递正比于环境温度 T_{amb} 和冷却水温度 T_{CL} 的差值，即：

$$T_{\text{HE}} = \frac{(T_{\text{amb}} - T_{\text{CL}}) k_{\text{HE}}}{\dot{m} c_{\text{p,CL}}} + T_{\text{CL}} \quad (2.78)$$

如果冷却风扇速度可以连续调节，那么可以认为式中的比例系数 k_{HE} 是风扇速度的函数。如果冷却风扇只有开和关两种状态，那么式中的比例系数 k_{HE} 就应该对应着两个值 $k_{\text{HE}}^{\text{on}}$ 和 $k_{\text{HE}}^{\text{off}}$ 。

2.3.7 小结

本节在分析燃料电池系统机理的基础上建立了燃料电池系统的数学模型，包括电堆电压模型、阴极和阳极模型、水传递模型及温度模型，并建立了各个辅助设备的数学模型，包括风机、氢气循环泵、加湿器、水循环泵、水箱、热交换器。这为开发燃料电池模拟仿真软件及设计燃料电池系统控制策略打下了坚实的基础。

2.4 燃料电池系统神经网络建模

从以上建立的燃料电池系统数学模型中可以看出, 燃料电池系统是一个极其复杂的非线性系统, 输出电压 V_{st} 是关于空压机控制电压 V_{cm} 、增湿水量 $W_{v, inj}$ 、散热风扇控制电压 V_{fan} 、循环水泵控制参数 V_{wp} 及负载电流扰动 I_{st} 的函数:

$$V_{st} = F(V_{cm}, W_{v, inj}, V_{fan}, V_{wp}, I_{st}, t) \quad (2.79)$$

从燃料电池极化曲线就可看出, 当系统输入 I_{st} 增大 α 倍时 (α 为任意常数), 显然其响应 V_{st} 并不增大 α 倍, 即 $\alpha F(I_{st}) \neq F(\alpha I_{st})$ 。同理, 该函数也不满足线性可加性。模型内部存在着大量的非线性计算, 如电堆温度 T_{st} 和阴极流道内的饱和蒸气压 $P_{sat, ca}$ 就存在严重的非线性关系^[34]:

$$P_{sat, ca} = P_0 \times 10^{2.953 \times 10^{-2} (T_{st} - 273) - 9.1837 \times 10^{-5} (T_{st} - 273)^2 - 1.4454 \times 10^{-7} (T_{st} - 273)^3 - 2.1794} \quad (2.80)$$

因此燃料电池系统是一个动态、连续的非线性系统。同时, 各输入变量间存在着强耦合关系。例如, 从式 (2.3) 可看出 E_0 是在阴极的氧气分压 p_{O_2} 的函数, 而变量 p_{O_2} 不仅跟空压机控制输入 V_{sm} 有关, 而且还与温度 T_{st} 有关, 如式 (2.15) 所示, 也就是说与散热风扇控制电压 V_{fan} 和循环水泵功率 p_p 有关。同理还有平均含水量 λ_m 不仅和增湿水量 $W_{v, inj}$ 有关, 还与阴极压力和阳极压力有关, 如式 (2.43) 所示, 即跟 V_{sm} 、 T_{st} 有关。所以燃料电池发动机系统是一个具有强耦合特性的非线性系统。

上节建立的燃料电池系统模型, 是辨识模型和机理模型的综合, 建模过程中用到了大量的假设。大量过程的简化和参数的假定, 使模型与直接应用于实际的系统还有些差距。而且, 由于模

型过于复杂,存在着大量的计算,很难用于实时的在线控制系统中。相比之下,神经网络在这方面显示了明显的优越性。近年来,人们将神经网络模型引入非线性系统建模和辨识中,利用神经网络所具有的对任意非线性映射的任意逼近能力,来模拟实际系统的输入/输出关系;利用神经网络的自学习、自适应能力,可以方便地给出工程上易于实现的学习算法,经过训练得到动态系统的正向或逆向模型^[41]。

本节将视燃料电池发统为“黑箱”,利用神经网络可以任意逼近复杂非线性函数的能力,建立 PEM 燃料电池系统神经网络模型。

2.4.1 非线性动态系统神经网络辨识

人工神经网络是一个由大量的简单基本元件——神经元相互连接而成的自适应非线性动态系统,每个神经元的结构和功能比较简单,但大量神经元组合产生的系统行为却非常复杂。神经网络自问世以来,在模式识别、信号检测、图像处理、自适应滤波、函数逼近、逻辑映射等领域得到了广泛的应用。

设 P 表示被识别的系统, U 、 Y 分别表示输入、输出空间,则 $P: U \rightarrow Y$, 即可将 P 看做是从输入空间至输出空间的算子,它以输入/输出对 $\{u, y\}$ 的形式隐含定义系统。设 $\{u(kT), y(kT)\}$ 是被辨识动态系统 P 经采样得到的输入/输出时间序列, T 是采样周期,因此可将 $\{u(kT), y(kT)\}$ 简写为 $\{u(k), y(k)\}$ 。

基于神经网络的系统辨识,就是选择适当的神经网络作为被辨识系统 P 的模型 \hat{P} 、逆模型 \hat{P}^{-1} (假定 P 是可逆的),也就是用神经网络来逼近实际系统或其可逆。神经网络用于系统辨识的一个优点就是不需要预先建立实际系统的辨识格式,它对系统的辨识过程就是直接学习系统的输入、输出数据的过程。学习的目的是使所要求的误差准则函数达到最小^[42], 即:

$$J = \|y(k) - y_N(k)\| = \|d\| < \varepsilon \quad (2.81)$$

式中, $\varepsilon > 0$, 是预先设定的一个量; $y(k)$ 为系统输出序列; $y_N(k)$ 为模型输出序列。这样即可归纳出隐藏在系统输入、输出数据中的映射关系。这个关系就是描述系统动态特性的算子 P , 当学习完成后, P 隐含在神经网络内部, 其表现形式如何, 对外界而言是不可知的。只要神经网络的输出能够逼近在同样输入信号激励下的输出, 就认为神经网络已充分描述了实际系统的特性并完成了对原系统的辨识。

基于输出误差的神经网络辨识结构如图 2.10 所示^[43]。正向辨识结构如图 2.10 (a) 所示, 训练神经网络来学习系统的正向动态特性, 学习结束后, 神经网络模型与实际系统具有相同的输入、输出映射特性。逆向辨识结构如图 2.10 (b) 所示, 其目标是建立系统的逆模型, 以 $u(k)$ 和 $y(k)$ 来训练一个神经网络, 使该网络把未知系统的输出 $y(k)$ 作为网络的输入时, 网络的输出正好等于未知系统的输入 $u(k)$ 。

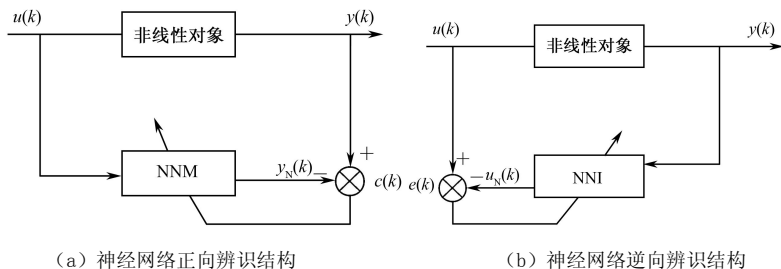


图 2.10 基于输出误差的神经网络辨识结构

神经网络系统辨识的步骤如图 2.11 所示。首先选择一个适当的神经网络结构作为系统的逼近模型, 选择时既要考虑神经网络对实际系统的精确逼近能力, 又要考虑模型的复杂性, 使所选择神经网络模型易于实现。神经网络模型选择好以后, 在分析系统影响因素的基础上, 把影响较大的因素作为系统的输入, 把系统

的响应作为模型的输出，用实测的样本对网络训练，通过误差来衡量神经网络模型逼近实际系统的程度。如果误差达不到要求，还可修改神经网络结构参数，如增加中间层神经元数目，以提高神经网络的逼近能力。

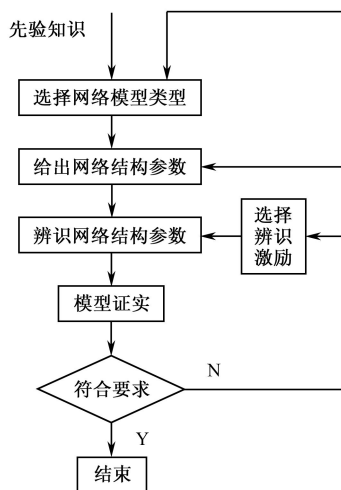


图 2.11 神经网络系统辨识的步骤

与传统辨识方法相比，神经网络不再要求建立实际系统的辨识格式，即可以省去对系统建模这一步骤，这种辨识是由神经网络本身来实现的，是非算法式的，这是目前非线性系统辨识中一种引人注目的新途径。

目前，神经网络已有几十种不同的模型，在这些模型中较常用的有前馈型的 BP (Back Propagation) 网络^[43~49]、RBF (Radial Basis Function) 网络^[43~49]、反馈型的 Elman 网络^[46~49]和 Hopfield 网络^[46~49]等。

1. BP 网络

BP 网络是一种单向传播的多层前馈型网络，是一种具有三层或三层以上的神经网络，包括输入层、中间层（隐含层）和输出层。BP 网络结构如图 2.12 所示。




图 2.12 BP 网络结构图

BP 算法是一种“误差逆传播算法”，学习过程由正向传播和反向传播组成。首先将学习样本对的输入加在网络的输入端，沿着前向（即输入层→输出层）在各层神经元按输入和激励函数（Sigmoid 函数）的方式产生输出；然后将输出层神经元的实际输出值和样本输出值之差按原连接通路反向计算（即输出层→输入层），由梯度下降法调整各层神经元的权值和阈值。此过程进行到神经网络权连接方式能在给定输入样本条件下以一定精度产生给定输出结果为止，即可认为学习阶段结束。

BP 网络的优点如下：

① 前馈型神经网络是一种强有力的学习系统，其分类能力和模式识别能力一般都强于反馈型网络。从理论上说，一个三层 BP 网络可以在任意精度内逼近任意函数，BP 网络已成为最为广泛应用的网络。

② 结构简单且易于编程，可通过简单的非线性处理单元的复合映射，获得复杂的非线性处理能力。

但是 BP 网络也存在一些缺点：

① 从计算的观点看，缺乏丰富的动力学行为。

② 由于采用误差函数梯度下降的方式进行迭代，就不可避免地产生陷入局部极值的问题。

③ 网络隐含层神经元数目的选取和连接权重初值的选取，往往靠经验或实验得到。

2. RBF 网络

径向基函数（RBF）网络是前馈型神经网络中一类特殊的三层神经网络。其隐含层单元的特性函数采用非线性的径向基函数，以对输入层的激励产生局部化响应，即仅当输入落在输入空间某一指定的小范围内时，隐藏单元才会做出有意义的非零响应。输出层节点则对隐藏节点的基函数输出进行线性组合。如图 2.13 所示是 RBF 网络结构。




图 2.13 RBF 网络结构图

RBF 网络的学习算法由两部分组成：无监督学习和有监督学习。隐含层单元学习时采用无监督学习的聚类算法，对所有样本

对输入进行聚类，求得各隐含层节点的 RBF 的中心和宽度；当输入信号与某隐含层单元的中心最接近时，该隐含层单元的输出最大；随着信号与中心的远离，隐含层单元的输出将会单调下降。输出神经元是一个线性求和器，所以学习采用有监督学习，如采用最小二乘法来完成学习。

RBF 网络与 BP 网络主要不同点是在非线性映射上采用了不同的作用函数，BP 网络采用 S 型函数，RBF 网络采用径向基函数。RBF 网络优点如下：

- ① 目前已证明 RBF 网络具有唯一最佳逼近的特性，且无局部极小。
- ② RBF 网络避免了像 BP 网络那样冗长的迭代计算过程，使学习速度比通常的 BP 算法快 $10^3 \sim 10^4$ 倍。
- ③ 具有结构自适应、输出与初始权值无关等特点。

缺点在于 RBF 网络隐藏节点的中心难求，这是该网络难以广泛应用的原因。

3. Hopfield 网络

Hopfield 网络是最典型的反馈网络模型，它是目前人们研究得最多的模型之一。Hopfield 网络是单层反馈型非线性网络，每一节点的输出均反馈至节点的输入，其结构如图 2.14 所示。




图 2.14 Hopfield 网络结构图

Hopfield 网络是一种互连型神经网络，所有神经单元之间相互连接，具有丰富的动力学特性。其特点是任何两个神经元之间都可能存在双向的连接关系，所有的神经元既作为输入节点，同时也作为输出节点。因此，输入信号要在所有神经元之间反复传递，从某一初始状态开始，经过若干次的变化，直到收敛于某一稳定状态或进入周期振荡等状态为止。

如果把系统的稳定点视为一个能量函数的极小点，而把能量函数视为一个优化问题的目标函数，那么从初态朝这个稳定点的演变过程就是求解该优化问题的过程。因此，Hopfield 网络的演变过程是一个求解优化问题的过程。实际上，它的解决并不需要真的去计算，而是通过构成反馈神经网络，适当地设计其连接权和输入就可以达到这个目的。

应用 Hopfield 网络对组合优化问题进行求解，在速度上有很大的优势，但是该方法借助 Lyapunov 方法的思想构造能量函数，但并不知道网络平衡点位置，不能保证 $\partial E / \partial t = 0$ 的点就是真正的极小点。由于 Hopfield 网络中没有隐含层，所以其非线性逼近能力较差。这种网络结构为全连接形式，当节点数目较多时，网络的结构就过于复杂。另外，因为其权值要求对称，而且神经元的输入、输出一般为二元形式，所以 Hopfield 网络一般用来解决模式识别等问题。

4. Elman 网络

Elman 网络是由 Elman 于 1990 年提出的，该模型在前馈网络的隐含层增加了一个承接层，作为一步延时算子，达到记忆的目的，从而使系统具有适应时变特性的能力，能直接反映动态过程系统的特性。

Elman 网络与 BP、RBF 等静态前馈网络不同，它具有内部反馈、存储和利用过去时刻输入、输出信息的特点，除了能解决静态系统的建模问题外，还能实现动态系统的映射并更加直接地反映系

统的动态特性，比前向神经网络系统具有更强的计算能力和网络稳定性。

在动态递归网络中，Elman 网络结构最为简单，运算量少，所以非常适合实时系统辨识。另外，由于 Elman 网络的动态特性由内部连接提供，网络训练时只需要输入、输出信号，不需要状态信息。

前馈型神经网络的特点是在前后相邻的两层之间神经元相互连接，在各神经元之间没有反馈。每一个神经元可以从前一层接收多个输入，并产生一个输出传递给下一层的各个神经元，信息只能从输入层开始逐层向前依次传递。利用静态前馈网络对动态系统进行辨识，实际上是将动态时间建模问题变为静态空间建模问题。例如，对于一个非线性时变系统：

$$y(k) = f(u(k), u(k-1), \dots, u(k-m-1), y(k-1), y(k-2), \dots, y(k-n)) \quad (2.82)$$

如用静态神经网络模型来逼近的话，输入节点数就需要 $m+n$ 个，网络输入节点过多，并且随着系统阶次的增加，网络结构也随之迅速扩大，使网络学习的收敛速度减慢，训练困难。另外，对于阶次未知的系统，还需要对模型结构进行定阶。相比之下，动态回归神经网络提供了一种极具潜力的选择，它是一种反馈动力学系统，比前馈型神经网络具有更强的计算能力，它能更生动、更直接地反映系统的动态特性，代表了神经网络建模、辨识与控制的发展方向。Elman 回归神经网络是一种典型的动态神经网络，在 BP 网络基本结构的基础上，通过存储内部状态使其具备映射动态特征的功能，从而使系统具有适应时变特性的能力。网络训练时只需要输入、输出信号，不需要状态信息。考虑到燃料电池系统具有动态特性，所以尝试采用 Elman 网络进行预测。

另外，研究神经网络的作用是为了建立燃料电池系统动态辨识模型，为下一步的优化控制做准备，因此，该神经网络最终将会移植到芯片上去。由于受到目前微控制芯片运算能力的限制，

必须尽可能地选择结构比较简单的神经网络，这样有利于实时系统的控制实现。Elman 网络是动态神经网络里面结构最为简单的神经网络。综上所述，最后确定 Elman 网络为燃料电池系统的辨识模型。

2.4.2 Elman 神经网络算法分析

1. Elman 神经网络拓扑结构

Elman 神经网络分为 4 层：输入层、中间层（隐含层）、承接层和输出层，如图 2.15 所示^[46~49]。

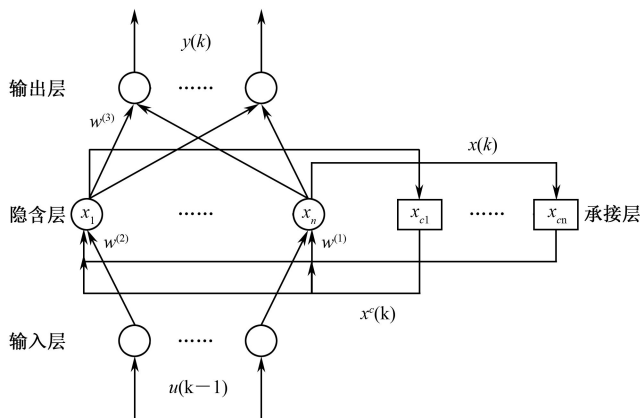


图 2.15 Elman 神经网络结构图

与前馈神经网络相比，其输入层、隐含层与输出层的连接类似于 BP 神经网络（前馈连接部分可进行连接权值的学习修正），输入层单元起信号传输作用，输出层单元起线性加权作用，隐含层单元的传递函数可采用线性或非线性函数。

Elman 神经网络的特点是在隐含层中增加了一个承接层，又称为上下文层或状态层（递归部分不进行连接权值的学习修正），它

用来记忆隐含层单元前一时刻的输出值，可以看成是一个一步延时算子。

通过承接层的延迟与存储，隐含层的输出自连到隐含层的输入，这种自连方式使其对历史状态的数据具有敏感性，内部反馈网络的加入增加了网络本身处理动态信息的能力。因此，Elman神经网络具有动态记忆功能和映射动态特征能力，有利于动态过程的建模，能够实现动态辨识的目的。

2. Elman 神经网络模型分析

根据图 2.15，Elman 神经网络的非线性状态空间表达式为：

$$\begin{cases} x(k) = f(w^{(1)} \cdot x^c(k) + w^{(2)} \cdot u(k-1) + \theta^{(1)}) \\ x^c(k) = x(k-1) \\ y(k) = g(w^{(3)} \cdot x(k) + \theta^{(2)}) \end{cases} \quad (2.83)$$

式中， $u(k)$ 为 Elman 神经网络在 k 时刻的输入； $w^{(1)}$ 为承接层与隐含层节点之间的连接权值矩阵； $w^{(2)}$ 为输入层与隐含层之间的连接权值矩阵； $w^{(3)}$ 为隐含层与输出层之间的连接权值矩阵； $\theta^{(1)}$ 为隐含层单元的阈值； $\theta^{(2)}$ 为输出层单元的阈值； $y(k)$ 为 Elman 神经网络在 k 时刻的输出； $x^c(k)$ 为承接层在 k 时刻的输出； $x(k)$ 为隐含层在 k 时刻的输出。

由式 (2.83) 可得：

$$x^c(k) = x(k-1) = f(w_{k-1}^{(1)} \cdot x^c(k-1) + w_{k-1}^{(2)} \cdot u(k-2) + \theta_{k-1}^{(1)}) \quad (2.84)$$

由式 (2.84) 可知， $x^c(k)$ 与前一时刻的 $x^c(k-1)$ 的值有关，显然这是一个动态递推的过程。

由于神经网络的非线性是由网络神经元中所具有的激活函数的非线性来决定的，而激活函数的选取是一个涉及神经元及网络的核心问题，因此网络解决问题的能力与功效除了与网络结构有关，在很大程度上取决于网络所采用的激活函数^[49]。Elman 神经网络隐含层神经元的激活函数 $f(\cdot)$ 采用 Sigmoid 函数：

$$f(x) = \frac{1}{1 + e^{-x}}, \quad 0 < f(x) < 1 \quad (2.85)$$

对 Sigmoid 函数求导, 得:

$$f'(x) = f(x)[1 - f(x)] \quad (2.86)$$

输出层神经元的激活函数 $g(\cdot)$ 采用 Pureline 函数:

$$y(k) = w^{(3)} \cdot x(k) + \theta^{(2)} \quad (2.87)$$

根据图 2.15 所示的 Elman 神经网络结构, 可得到如下关系式。

① 设输入层第 i 个神经元的输入为:

$$I_i^{(1)}(k) = u_i(k-1), \quad i=1, 2, \dots, S_1 \quad (2.88)$$

S_1 为输入层节点个数, 则输入层神经元的输出为:

$$O_i^{(1)}(k) = I_i^{(1)}(k) = u_i(k-1) \quad (2.89)$$

② 隐含层第 j 个神经元的输入为:

$$I_j^{(2)}(k) = \sum_{i=1}^{S_1} w_{ji}^{(2)} O_i^{(1)}(k) + \sum_{l=1}^{S_1} w_{jl}^{(1)} O_l^{(1)}(k) + \theta^{(1)}, \quad j=1, 2, \dots, S_2 \quad (2.90)$$

S_2 为隐含层节点个数, 则隐含层第 j 个神经元的输出为:

$$O_j^{(2)}(k) = f(I_j^{(2)}(k)) = \frac{1}{1 + e^{-(I_j^{(2)}(k))}} \quad (2.91)$$

③ 承接层第 l 个神经元的输入为:

$$I_l^c(k) = O_j^{(2)}(k), \quad l=1, 2, \dots, S_2 \quad (2.92)$$

则承接层第 l 个神经元的输出为:

$$O_l^c(t) = I_l^c(t) = x_l^c(t) \quad (2.93)$$

④ 输出层第 n 个神经元的输入为:

$$I_n^{(3)}(k) = \sum_{j=1}^{S_2} w_{nj}^{(3)} O_j^{(2)}(k) + \theta^{(2)}, \quad n=1, 2, \dots, S_3 \quad (2.94)$$

S_3 为输出层节点个数, 则输出层第 n 个神经元的输出为:

$$y_n(k) = O_n^{(3)}(k) = g(I_n^{(3)}(k)) \quad (2.95)$$

3. Elman 神经网络学习算法

Elman 神经网络的训练采用的是动态的 BP 算法。设第 p 组样本训练于网络时, 定义误差函数:

$$E = \frac{1}{2} \sum_{n=1}^{S_1} (y_n(k) - \hat{y}_n(k))^2 \quad (2.96)$$

式中, $y_n(k)$ 为教师信号, $\hat{y}_n(k)$ 为神经网络的输出层第 n 个神经元节点的输出值。将误差信号按原连接通路反向计算, 由输出层向输入层反向传递, 采用梯度下降法, 按误差函数的负梯度方向调整各层神经元的权值和阈值, 使误差信号减小。

(1) 计算连接权值修正量 Δw

依据梯度下降方法, Elman 网络中各层神经元的连接权值修正量, 正比于误差函数对该权值的负导数, 故有如下连接权值的修正量公式:

$$\Delta w = -\eta \frac{\partial E}{\partial w} \quad (2.97)$$

式中, η 为学习率, $0 < \eta < 1$ 。

首先, 将误差函数 E 对权值 $w_{nj}^{(3)}$ 求偏导数, 可得:

$$\frac{\partial E}{\partial w_{nj}^{(3)}} = \frac{\partial E}{\partial I_n^{(3)}(k)} \frac{\partial I_n^{(3)}(k)}{\partial w_{nj}^{(3)}} = \frac{\partial E}{\partial y_n(k)} \frac{\partial y_n(k)}{\partial I_n^{(3)}(k)} \frac{\partial I_n^{(3)}(k)}{\partial w_{nj}^{(3)}} \quad (2.98)$$

据式 (2.94), 得:

$$\frac{\partial I_n^{(3)}(k)}{\partial w_{nj}^{(3)}} = O_j^{(2)}(k) \quad (2.99)$$

据式 (2.95), 得:

$$\frac{\partial y(k)}{\partial I_n^{(3)}(k)} = g'(I_n^{(3)}(k)) \quad (2.100)$$

据式 (2.96), 得:

$$\frac{\partial E}{\partial y_n(k)} = -(\hat{y}_n(k) - y_n(k)) \quad (2.101)$$

据式 (2.98), 则有:

$$\frac{\partial E}{\partial w_{nj}^{(3)}} = \left(-(\hat{y}_n(k) - y_n(k)) \right) g'(I_n^{(3)}(t)) O_j^{(2)}(t) \quad (2.102)$$

定义:

$$\delta^{(3)} = (\hat{y}_n(k) - y_n(k)) g'(I_n^{(3)}(k)) \quad (2.103)$$

代入式 (2.102), 可得:

$$\frac{\partial E}{\partial w_{nj}^{(3)}} = -\delta^{(3)} O_j^{(2)}(k) \quad (2.104)$$

所以可求得隐含层到输出层各神经元连接权值的修正量为:

$$\Delta w_{nj}^{(3)} = -\eta \delta^{(3)} O_j^{(2)}(k) \quad (2.105)$$

将误差函数 E 对权值 $w_{ji}^{(2)}$ 求偏导数, 可得:

$$\begin{aligned} \frac{\partial E}{\partial w_{ji}^{(2)}} &= \frac{\partial E}{\partial O_j^{(2)}(k)} \frac{\partial O_j^{(2)}(k)}{\partial w_{ji}^{(2)}} \\ &= \left(\sum_{n=1}^S \frac{\partial E}{\partial y_n(k)} \frac{\partial y_n(k)}{\partial I_n^{(3)}(k)} \frac{\partial I_n^{(3)}(k)}{\partial O_j^{(2)}(k)} \right) \frac{\partial O_j^{(2)}(k)}{\partial I_j^{(2)}(k)} \frac{\partial I_j^{(2)}(k)}{\partial w_{ji}^{(2)}} \end{aligned} \quad (2.106)$$

据式 (2.90), 得:

$$\frac{\partial I_j^{(2)}(k)}{\partial w_{ji}^{(2)}} = O_i^{(1)}(k) = u_i(k-1) \quad (2.107)$$

据式 (2.91), 得:

$$\frac{\partial O_j^{(2)}(k)}{\partial I_j^{(2)}(k)} = f'(I_j^{(2)}(k)) \quad (2.108)$$

据式 (2.94), 得:

$$\frac{\partial I_n^{(3)}(k)}{\partial O_j^{(2)}(k)} = w_{nj}^{(3)} \quad (2.109)$$

据式 (2.100)、式 (2.101)、式 (2.103) 及式 (2.109), 可得:

$$\frac{\partial E}{\partial w_{ji}^{(2)}} = \sum_{n=1}^{S_3} (-\delta^{(3)} w_{nj}^{(3)}) f'(I_j^{(2)}(k)) u_i(k-1) \quad (2.110)$$

定义:

$$\delta^{(2)} = \sum_{n=1}^{S_3} \delta^{(3)} w_{nj}^{(3)} f'(I_j^{(2)}(k)) \quad (2.111)$$

据式 (2.106), 则有:

$$\frac{\partial E}{\partial w_{ji}^{(2)}} = -\delta^{(2)} u_i(k-1) \quad (2.112)$$

所以输入层到隐含层各神经元连接权值的修正量为:

$$\Delta w_{ji}^{(2)} = -\eta \delta^{(2)} u_i(k-1) \quad (2.113)$$

将误差函数 E 对权值 $w_{ji}^{(1)}$ 求偏导数, 可得:

$$\frac{\partial E}{\partial w_{ji}^{(1)}} = \frac{\partial E}{\partial O_j^{(2)}(k)} \frac{\partial O_j^{(2)}(k)}{\partial w_{ji}^{(1)}} \quad (2.114)$$

据前面的推导过程有:

$$\frac{\partial E}{\partial O_j^{(2)}(k)} = \sum_{n=1}^{S_3} (-\delta^{(3)} w_{nj}^{(3)}) \quad (2.115)$$

所以

$$\frac{\partial E}{\partial w_{ji}^{(1)}} = \left(\sum_{n=1}^{S_3} (-\delta^{(3)} w_{nj}^{(3)}) \right) \frac{\partial O_j^{(2)}(k)}{\partial w_{ji}^{(1)}} \quad (2.116)$$

由于承接层输出函数 $O_i^c(t)$ 相关于连接权 $w_{ji}^{(1)}$, 故

$$\begin{aligned} \frac{\partial O_j^{(2)}(k)}{\partial w_{ji}^{(1)}} &= \frac{\partial}{\partial w_{ji}^{(1)}} \left(f_j \left(\sum_{i=1}^{S_1} w_{ji}^{(1)} O_i^{(1)}(k) + \sum_{l=1}^{S_2} w_{lj}^{(1)} O_l^c(k) + \theta^{(1)} \right) \right) \\ &= f'_j(\bullet) \left\{ O_i^c(k) + \sum_{l=1}^{S_2} w_{lj}^{(1)} \frac{\partial O_l^c(k)}{\partial w_{lj}^{(1)}} \right\} \\ &= f'_j(\bullet) \left\{ O_j^{(2)}(k-1) + \sum_{l=1}^{S_2} w_{lj}^{(1)} \frac{\partial O_j^{(2)}(k-1)}{\partial w_{lj}^{(1)}} \right\} \end{aligned} \quad (2.117)$$

据式 (2.116) 和式 (2.117), 得:

$$\frac{\partial E}{\partial w_{jl}^{(1)}} = \left(\sum_{n=1}^{S_k} (-\delta^{(3)} w_{nj}^{(3)}) \right) \left(f_j'(\bullet) \left\{ O_j^2(k-1) + \sum_{l=1}^{S_2} w_{lj}^{(1)} \frac{\partial O_j^2(k-1)}{\partial w_{lj}^{(1)}} \right\} \right) \quad (2.118)$$

即可求得承接层到隐含层各神经元连接权值的修正量为:

$$\Delta w_{jl}^{(1)} = -\eta \frac{\partial E}{\partial w_{jl}^{(1)}} \quad (2.119)$$

(2) 计算各层阈值的修正量 $\Delta \theta$

同理, 依据梯度下降方法对 Elman 网络中各层神经元的阈值进行修正。

$$\Delta \theta = -\eta \frac{\partial E}{\partial \theta} \quad (2.120)$$

按上述连接权值修正量的推理分析方法, 求得 Elman 隐含层到输出层阈值修正量 $\Delta \theta^{(2)}$ 为:

$$\Delta \theta^{(2)} = -\frac{\eta}{N_p} \frac{\partial E}{\partial \theta^{(2)}} = -\frac{\eta}{N_p} \sum_{j=1}^{S_2} \delta^{(3)} \quad (2.121)$$

输入层到隐含层的阈值修正量 $\Delta \theta^{(1)}$ 为:

$$\Delta \theta^{(1)} = -\frac{\eta}{N_p} \frac{\partial E}{\partial \theta^{(1)}} = -\frac{\eta}{N_p} \sum_{i=1}^S \delta^{(1)} \quad (2.122)$$

2.4.3 基于 Elman 神经网络的燃料电池系统辨识

1. Elman 神经网络模型的构建

本节研究对象是 PEM 燃料电池系统, 包含电堆和整个辅助系统。前面已经详细论述了燃料电池系统是一个极其复杂的非线性系统, 输出电压 V_{st} 受空压机控制电压 V_{cm} 、增湿水量 $W_{v, inj}$ 、散热风扇控制电压 V_{fan} 、循环水泵控制频率 f_p 及负载电流扰动 I_{st} 等众多因素的影响。根据实验条件, 考虑到模型既要简单又能正确地映射出燃料电池的性能, 输入量选取为空压机控制电压 V_{cm} 、循环水泵控制频率 f_p 、散热风扇控制电压 V_{fan} 、负载电流扰动 I_{st} , 输

出量为电堆的电压 V_{st} 和电堆温度 T_{st} 。

另外，考虑到时滞系统的未来响应特性与系统当前时刻的状态有关，与当前及过去时刻系统的状态变化趋势有关，经过仿真分析，为改善神经网络的多步预测结果，提高神经网络对动态系统的辨识精度，只要将系统实际输出值的变化趋势，即在第 $k-1$ 时刻的值 $y(k-1)$ 及其变化率 $\Delta y(k-1) = y(k-1) - y(k-2)$ 输入网络的输入层即可。由于 Elman 网络自身含有动态环节，因此，无须使用较多系统状态作为输入，从而减少了输入层单元数。

Elman 神经网络建模示意图如图 2.16 所示。




图 2.16 Elman 神经网络建模示意图

其非线性映射关系为：

$$\{V_{st}(k), T_{st}(k)\} = \text{ENN}[V_{cm}(k-1), f_p(k-1), V_{fan}(k-1), I_{st}(k-1), \\ V_{st}(k-1), \Delta V_{st}(k-1), T_{st}(k-1), \Delta T_{st}(k-1)] \quad (2.123)$$

采用 MATLAB 神经网络工具箱函数 newelm, 建立一个可训练的 Elman 网络。指令格式如下：

```
net=newelm
net=newelm(PR, [S1 S2 ...SN], {TF1 TF2 ...TFN}, BTF, BLF, PF)
```

其中, $\text{net}=\text{newelm}$ 用于在对话框中创建一个 Elman 网络; PR 表示 R 组输入元素的最小值和最大值的设定值, 是 $R \times 2$ 维的矩阵; S_i 表示第 i 层的神经元个数, 总共 N 层; TF_i 表示第 i 层的传递函数, 默认值为 “tansig”; BTF 表示 BP 网络训练函数, 默认值为 “traingdx”; BLF 表示 BP 网络权值/阈值学习函数, 缺省值为 “learngdm”; PF 表示性能函数, 默认值为 “mse”。

执行结果: 创建了一个 N 层的 Elman 神经网络。

TF_i 的值可以是任何的可微函数, 如 S 型的对数函数 logsig 、纯线性函数 purelin 等。BTF 的值还可以选择梯度下降 BP 算法函数 traingd 、梯度下降动量 BP 算法函数 traingdm 、自适应梯度递减训练函数 traingda 、动量及自适应梯度递减训练函数 traingdx 等训练函数。BLF 的值还可以选择基于梯度下降法的学习函数 learngd 和梯度下降动量学习函数 learngdm 。PF 的值可以是任何的可微性能函数, 如均方误差函数 mse 、均方误差规范化函数 msereg 。

输入与输出层的神经元数目是由问题的类别和应用要求决定的, 但应注意尽可能减小系统的规模, 以降低学习的时间和系统的复杂性。这里取输入神经元为 8 个, 输出神经元是 2 个。

目前已有很多关于如何确定隐含层神经元个数的论文和研究, 但是所得出的结果却千差万别。例如, 文献[50]对 n 维超立方体顶点进行二分类, 得出的二进前向网络的隐节点数的上界为 $2^{n-1}/3$, 而文献[51]通过构造法得到的隐节点数的最小上界仅为 $2n-3$, 两个结果具有指数级和线性级的巨大差异。文献[52]介绍了 3 种选择隐含层单元数 n_l 的公式:

$$\begin{cases} k < \sum_{i=0}^n C \begin{pmatrix} n_1 \\ i \end{pmatrix} \\ n_1 = \sqrt{n+m+a} \\ n_1 = \log_2 n \end{cases} \quad (2.124)$$

式中, k 为样本数; n 为输入层单元数; 当 $i > n_1$ 时, 取 $C \begin{pmatrix} n_1 \\ i \end{pmatrix} = 0$;

m 为输出层单元数; a 为 $[1, 10]$ 之间的常数。

这 3 个式子, 不仅数值不同, 而且数量级不同, 隐含层节点数的影响因素也各不相同。因此, 很难找到有关其特性的解析表达式。但有些共性结论有助于确定隐含层节点数: 隐含层神经元过少时, 网络或许不能收敛到规定误差; 神经元过多, 则学习后网络的泛化能力变差; 如果要求逼近的样函数变化剧烈、波动很大, 则要求可调整的连接数多, 从而隐藏节点也应当多些。本书采用试凑法来确定隐藏单元神经元数目, 在开始时放入比较少的神经元, 学习到一定次数后, 如果不成功则再增加神经元的数目, 直到达到比较合理的隐含层神经元数目为止。

初始权值的设置对神经网络的训练速度影响非常大, 理想的初始权值能使神经网络较快地收敛到最优解。如果初始权值选择不当, 选择在局部极小值附近, 则神经网络训练得到的很有可能是局部最小解, 而得不到全局最小解。若初始权值落在平坦区, 则使神经网络长时间得不到收敛, 造成训练时间过长。因此, 对于初始权值的确定, 一般选取一个比较小的随机数。根据经验, 若一个神经网络的输入向量维数为 q , 则初始权值可在 $[0, 1/\sqrt{q}]$ 之间。这样就可以保证每个神经元从一开始就在它激励函数变换最大的地方。

2. 学习样本的确定及归一化

学习样本的作用在于训练网络, 即调整网络的连接权值, 使

网络的输出与实际输出的误差达到最小。一旦网络结构和算法确定下来,学习样本数及其代表性就成为决定网络映射及泛化能力的最终因素。为给网络提供能全面、正确地反映系统特性的输入/输出模式对,学习样本应具有3个特性:致密性、遍历性和相容性。

致密性是指在有限的样本空间内选取的学习样本数量越大,密度就越高。为获得一定的映射精度,映射关系越复杂,应提供的样本数便越多。另外,样本数将随着噪声的增大而增多。遍历性是指学习样本是否遍历了其可能存在的所有空间。如果学习样本取得不充分,甚至某个子区域的样本根本没有取到,那么这样训练出来的网络泛化能力肯定不高。样本的相容性主要考虑的是不同类别的样本的输入空间存在交叠区域时对网络学习的影响。综合上述3个方面可以看出,学习样本的性能对神经网络的训练有着极为重要的影响,选择样本应从多方面综合考虑。

实验数据由武汉理工大学燃料电池发动机实验室测得。选择样本的依据为:①样本尽可能全面地反映燃料电池发动机系统的工作范围和动态特性;②样本数目尽可能少,以较少的实验次数减小训练网络所占用的资源;③由样本训练好的网络应具有良好的内插和外推性能。样本数据分训练数据和测试数据,训练样本选取了2000组具有代表性的数据,测试样本另外选取2000组数据用来验证网络泛化性能。

在这些数据使用之前,要先对输入、输出样本数据进行归一化处理。虽然理论上神经网络对输入量是无限制的,但由于样本的各个指标不相同,原始样本中各变量的数量级差别很大,为了使各变量的重要性处于同等地位,必须进行归一化处理。Elman网络的输出样本也要进行归一化处理。因为Elman算法力图减小输出层各神经元输出误差的平方和,如果各输出变量在数值上相差太大,显然那些输出值大的神经元的误差是网络误差中的主要成分,从而得到算法的“特别关照”,导致那些数值较小的输出变量的相对误差较大^[46]。因此,在燃料电池系统神经网络建模中,

对样本数据必须进行归一化处理:

$$\bar{u}_i = \frac{u_i - u_{i\min}}{u_{i\max} - u_{i\min}} \quad (2.125)$$

式中, u_i , $u_{i\max}$, $u_{i\min}$ 分别表示第 i 个影响因子及其在学习样本中的最大、最小值; \bar{u}_i 表示归一化后的第 i 个输入变量, 其范围为 $0 \sim 1$ 。

Elman 网络要求输入的形式为元矩阵向量模式, 可以通过调用函数 `con2seq` 将普通向量模式转换成元矩阵向量模式。在进行仿真以后, 网络输出为元矩阵向量模式, 此时, 可以调用函数 `seq2con` 将元矩阵向量模式转换成普通向量模式。

3. Elman 神经网络的学习、训练和仿真

在燃料电池系统神经网络模型中, 隐含层的传递函数采用双曲正切 S 型函数 `tansig`, 输出层采用纯线性函数 `purelin`, 学习函数采用 `learngd`, 训练函数采用 `traingd`, 性能函数采用 `mse`, 用系统正常工作情况下的 2000 组数据作为训练样本, 训练该 Elman 网络。

在 Elman 网络学习过程中, 学习率 η 的选择很重要。在梯度下降法中, 学习率选择较小值, 可使网络总误差函数 E 达到最小值; 学习率如果过小, 则会使学习过程变得非常缓慢, 收敛速度很慢, 增加了网络的学习时间, 如果误差函数有许多局部极小值, 则会使网络陷入局部最小值或进入平稳停滞状态。学习率如果选得较大, 则权值更新加大, 有可能加快收敛速度; 但若学习率选得过大, 则可能造成算法的不稳定, 甚至有可能引起迭代的剧烈振荡, 无法收敛。根据燃料电池发动机系统的特性, 选择初始学习率为 0.1。

利用 MATLAB 神经网络工具箱对此网络进行模型训练与仿真, 根据经验, 先将中间层神经元数目设置为 11, 设定训练步数为 1000, 训练结果如图 2.17 所示, 网络的训练误差为 7.87×10^{-4} 左右, 已在可接受误差范围内。

网络训练完成后要进行测试，以检测网络的预测性能是否满足要求。如果满足要求，就可以利用它来解决实际问题。为了保证测试结果的有效性和准确性，测试数据应该避免与训练数据相一致。这里另取系统正常工作情况下的 2000 组数据作为测试样本，误差曲线如图 2.18 所示，误差小于 0.015。




图 2.17 训练结果（中间层神经元数目为 11）




图 2.18 误差曲线（中间层神经元数目为 11）

为了检验中间层神经元数目对于网络预测性能的影响，将其分别设定为 17 和 22 后，观察其训练结果和误差曲线，如图 2.19～图 2.22 所示。




图 2.19 训练结果（中间层神经元数目为 17）




图 2.20 误差曲线（中间层神经元数目为 17）




图 2.21 训练结果（中间层神经元数目为 22）




图 2.22 误差曲线（中间层神经元数目为 22）

显然当中间层神经元数目 17 时，网络的预测误差最小，也就是预测性能最好。因此，在本燃料电池系统神经网络模型中，中间层神经元数目最终确定为 17。

2.4.4 模拟仿真及结果分析

Elman 神经网络预测模型的曲线拟合结果如图 2.23 和图 2.24 所示。图 2.23 为电流变化情况下电堆输出电压仿真曲线与实验数据曲线拟合。由图 2.23 可知，电堆负载电流越大，电堆输出电压越低，这符合燃料电池极化曲线的变化趋势。此时神经网络对电流扰动变量和电堆电压之间非线性映射关系的拟合是比较精确的，测试结果与仿真结果基本一致。

图 2.24 为功率给定 50kW 时，风机控制电压和电堆输出电压仿真曲线与实验数据曲线拟合的情况。从图中可看出，风机控制电压越高，电机转速越快，致使阴极氧气流量和压力变大，电堆电压会有所提高，但随着时间推移电堆电压会慢慢下降，这是由于燃料电池本身的一个衰减特性决定的，也有可能是由于时间长了，发生堵水现象。测试结果与仿真结果基本一致。

由此可见，Elman 神经网络预测模型可对燃料电池输出特性进行有效预测。




图 2.23 电流变化情况下电堆输出电压仿真曲线与实验数据曲线拟合




图 2.24 风机控制电压和电堆输出电压仿真曲线与实验数据曲线拟合

2.4.5 小结

本节从系统的角度出发，提出了基于 Elman 神经网络的燃料电池系统模型，并利用该模型进行了动态特性研究。本节首先对目前最常用的几个典型的前馈神经网络模型和反馈神经网络模型进行了详细的分析，在比较各自的优缺点后，结合燃料电池系统本身的特点，选取 Elman 神经网络作为燃料电池系统的逼近模型。采用 2000 组训练样本参加训练，并采用另外 2000 组测试样本对网络进行测试，经过不同中间层神经元的神经网络预测误差比较后，最后确定 Elman 神经网络的内部结构。仿真结果表明神经网络输出与实验输出基本吻合，验证了所建立的 Elman 神经网络模型能较好地逼近实际的燃料电池系统，为燃料电池系统预测控制提供了较为准确的数学模型。

第3章 质子交换膜燃料电池系统模拟仿真

本章在第2章建立燃料电池系统机理模型的基础上，利用MATLAB软件中的Simulink，开发燃料电池系统模拟仿真软件，为燃料电池系统结构设计、动态分析和控制算法设计提供帮助；并对燃料电池系统进行仿真，对影响燃料电池系统运行的各种操作条件和结构参数进行分析。

3.1 概述

第2章建立了燃料电池系统模型，下一步的工作是利用MATLAB软件中的Simulink进行仿真。在燃料电池动态分析与仿真过程中，Simulink虽然操作简单，效率高，但是修改参数不方便，尤其不适合非专业人员使用。因此，在模型调试完成之后，需要设计一个比较友好的操作界面，方便用户的操作，直观且高效。利用GUI设计的界面不仅可以对输入参数进行修改，还可以调入不同的采集数据和各种参数，对仿真的结果给出图形和文字显示，界面友好，具有开放性，方便不同用户的使用，以及不断完善和扩充其功能。本章在上一章建立了燃料电池系统模型的基础上，开发燃料电池系统模拟仿真软件。

3.2 燃料电池系统模拟仿真软件开发

燃料电池系统模拟仿真软件包括输入界面、Simulink 模型和输出界面，下面详细介绍。

3.2.1 输入界面

燃料电池系统模拟仿真软件输入界面是用 MATLAB 做的一个人机界面，可以通过这个人机界面输入仿真需要的一些初始条件和参数，燃料电池模拟仿真软件输入界面如图 3.1 所示。输入的值包括单电池参数、电堆体积参数、其他参数、仪器型号和初始条件。单电池参数包括数量、面积、最小电压和电堆电流，其中，数量指电堆中单电池片数；面积指单电池面积，单位为平方厘米 (cm^2)；最小电压指发电时单电池能够忍受的最低电压，单位为伏特 (V)；电堆电流指施加到单电池上的电流，单位为安培 (A)。电堆体积参数包括阴极、阳极、供应管腔和回流管腔，单位都是立方米 (m^3)，阴极指电堆中单电池的阴极体积集总为一个整体的体积；阳极指电堆中单电池的阳极体积集总为一个整体的体积；供应管腔指电堆中单电池的供应管腔体积集总为一个整体的体积；回流管腔指电堆中单电池的回流管腔体积集总为一个整体的体积。其他参数包括 k_{sm} 、 k_{tm} 、 k_{out} 和最大冷却温度， k_{sm} 为计算阴极进口流量时的系数， k_{tm} 为计算回流管腔流量时的系数， k_{out} 为计算阴极出口流量时的系数，最大冷却温度是指为了保护电堆冷却水温度的上限，单位是 K。初始条件指燃料电池系统开始仿真时的初始状态，包括环境温度、水箱温度、散热器温度、阴极出口温度、压缩机出口温度、加湿器出口温度、冷却水流量、加湿器

流量、冷却剂最小环境压力，温度的单位是 K，流量的单位是 kg/s，压力的单位是 bar。仪器型号是将各种辅助设备建立模型，并将相关参数保存在数据库中，在模拟仿真时可以选择设备型号进行仿真，检验该型号设备能否满足燃料电池系统的需要，辅助设备包括水箱、加湿器、冷凝器和空气压缩机，在操作时可以在相应设备后的下拉列表框中选取某一型号的设备进行仿真。输入界面的最下方有一个“开始仿真”按钮，单击“开始仿真”按钮就可以将相应参数传送到 Simulink 模型中进行仿真。

燃料电池计算机模拟仿真系统

燃料电池参数	其他参数	初始条件
数量: <input type="text"/> cm²	Ksm: <input type="text"/>	环境温度: <input type="text"/> (K)
面积: <input type="text"/> cm²	Km: <input type="text"/>	水箱温度: <input type="text"/> (K)
最小电压: <input type="text"/> (V)	Kout: <input type="text"/>	散热器温度: <input type="text"/> (K)
电堆电流: <input type="text"/> (A)	最大冷却温度: <input type="text"/> (K)	阴极出口温度: <input type="text"/> (K)
各参数体积 阴极: <input type="text"/> m ³ 阳极: <input type="text"/> m ³ 供应管腔: <input type="text"/> m ³ 回流管腔: <input type="text"/> m ³		压缩机出口温度: <input type="text"/> (K) 加湿器出口温度: <input type="text"/> (K) 冷却水流量: <input type="text"/> kg/s 加湿器流量: <input type="text"/> kg/s 冷却剂最小环境压力: <input type="text"/> (bar)
仪器型号 水箱: <input type="text" value="水箱1"/> 加湿器: <input type="text" value="加湿器1"/> 冷凝器: <input type="text" value="冷凝器1"/> 空气压缩机: <input type="text" value="风机1"/>		
<input type="button" value="开始仿真"/>		

图 3.1 燃料电池模拟仿真软件输入界面

3.2.2 Simulink 模型

根据第 2 章所建立的数学模型，利用 MATLAB 中的 Simulink 建立模型，燃料电池系统 Simulink 模型如图 3.2 所示。图 3.2 中的“Subsystem3”是 Simulink 子系统，该子系统为描述温度模型

的子系统,如图 3.3 所示。图 3.3 中又有 3 个子系统,分别为 Q_{elec} 子系统、 Q_{sens} 子系统和 Q_{latent} 子系统。 Q_{elec} 子系统描述燃料电池堆产生的电能 q_{elec} , Q_{sens} 子系统描述燃料电池堆中流体的温度转化成标准温度的能量 q_{sens} , Q_{latent} 子系统描述燃料电池阴极和阳极中的水蒸发或冷凝时产生的能量 q_{latent} 。

图 3.1 中还有个子系统 V_{st} ,它是描述电堆电压模型的,该子系统如图 3.4 所示。在图 3.4 中可见,该子系统又包括 4 个子系统,分别为热力学电势子系统、 V_{act} 子系统、 V_{ohm} 子系统和 V_{conc} 子系统。热力学电势子系统描述燃料电池开环电路电压的计算, V_{act} 子系统描述活化损失电动势的计算, V_{ohm} 子系统描述欧姆损失电动势的计算, V_{conc} 子系统描述浓差损失电动势的计算。

3.2.3 输出界面

输出界面如图 3.5 所示。图 3.5 中显示了电堆电压、电堆温度、空气流量及循环水流量随时间变化的值,这些值可以用图 3.5 中的数字表示,还可以用实时曲线来表示。

3.3 燃料电池动态分析及仿真结果

根据以上开发的燃料电池模拟仿真软件,下面对燃料电池系统进行动态分析和仿真,相关参数见表 3.1。

首先对空气供应系统进行仿真,当 $k_{\text{sm}}=2 \times 10^{-3}$, $k_{\text{out}}=1 \times 10^{-4}$, $k_{\text{m}}=2 \times 10^{-3}$, 风机转速为 3500rpm, 输出电流为 200A 时, 阴极氧气质量 m_{O_2} 、阴极气体压力 P_{ca} 变化如图 3.6 和图 3.7 所示。从图中可以看出, 阴极氧气质量和阴极气体压力的响应比较快, 响应时间大约在 0.1 秒左右^[53]。

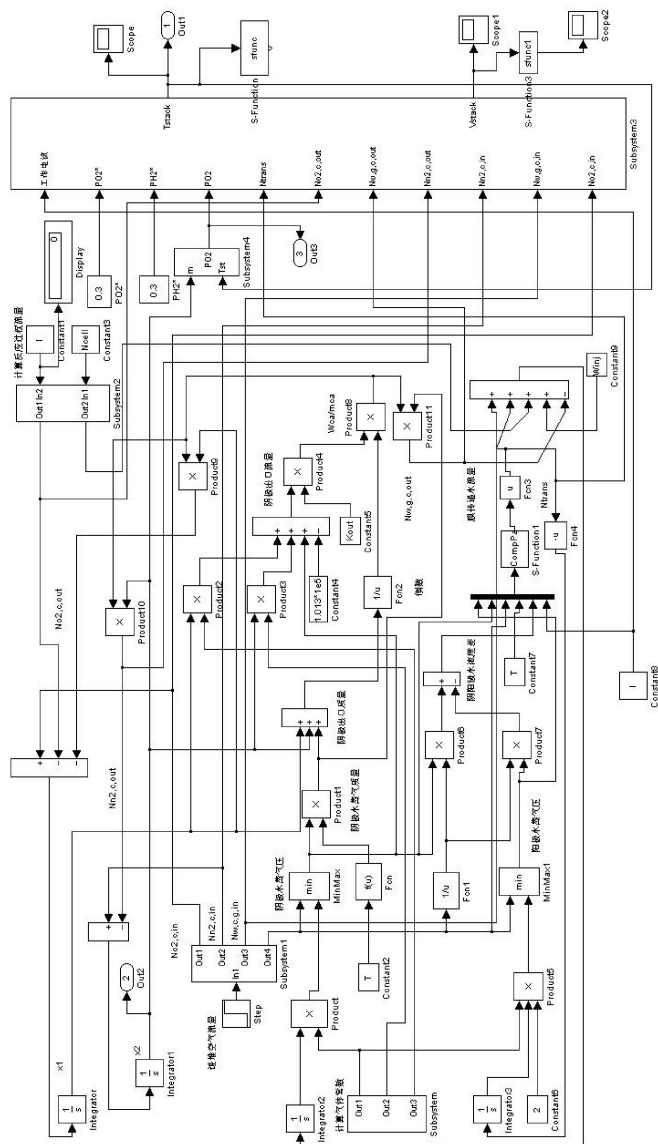


图 3.2 燃料电池系统 Simulink 模型

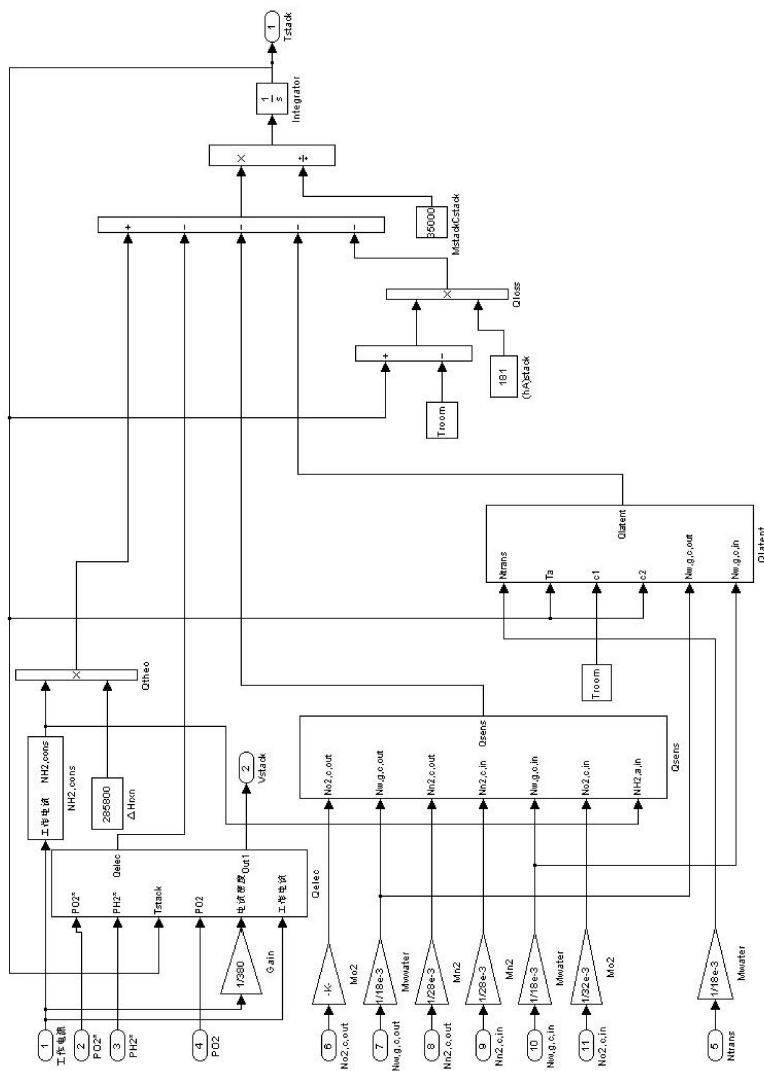


图 3.3 温度子系统 Simulink 模型

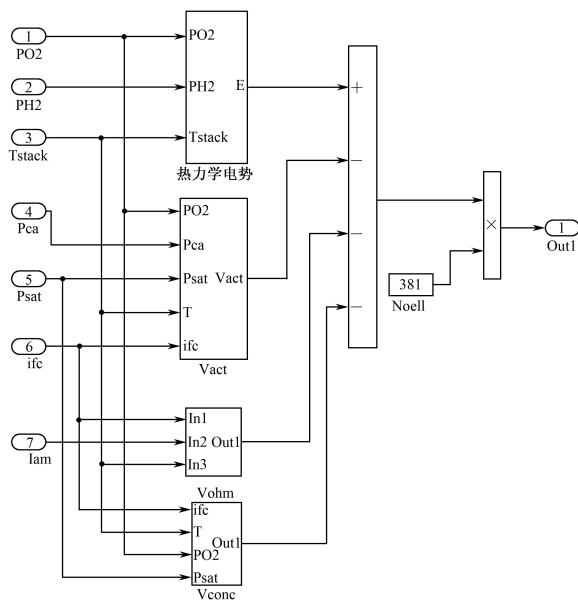


图 3.4 电堆电压子系统 Simulink 模型

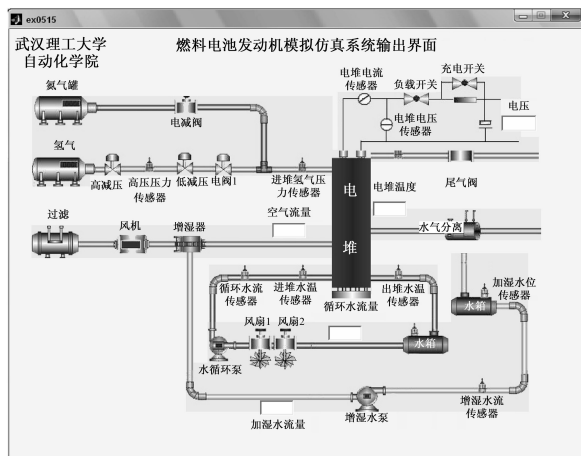


图 3.5 输出界面

第3章 质子交换膜燃料电池系统模拟仿真

表3.1 动态分析与仿真相关参数

参 数	含 义	值
M_{O_2}	氧气摩尔质量	$32 \times 10^{-3} \text{ kg/mol}$
M_{N_2}	氮气摩尔质量	$28 \times 10^{-3} \text{ kg/mol}$
R_{N_2}	氮气气体常数	$296.8 \text{ J/(kg} \cdot \text{K)}$
R_{O_2}	氧气气体常数	$259.8 \text{ J/(kg} \cdot \text{K)}$
R_a	空气气体常数	$286.9 \text{ J/(kg} \cdot \text{K)}$
P_{atm}	空气压力	101.325 kPa
N	电堆中单电池数目	254
V_{ca}	阴极体积	0.0067 m^3
V_{rm}	回流管腔体积	0.00167 m^3
V_{sm}	供应管腔体积	0.0133 m^3
F	费南德常数	96485




图 3.6 阴极氧气质量变化图

当 $k_{sm}=2\times 10^{-3}$ ， $k_{out}=1\times 10^{-4}$ ， $k_{rm}=2\times 10^{-3}$ ，燃料电池堆电流有跳变，0~5 秒电流为 200A，5~10 秒电流为 300A，风机转速为 3500rpm 时，阴极氧气质量 m_{O_2} 随时间的变化如图 3.8 所示。其他条件不变，当风机转速为 3000rpm 时，阴极氧气质量 m_{O_2} 随时间的变化如图 3.9 所示。从图 3.8 可以看出，当风机转速为 3500rpm 时，随着电流从 200A 跳变到 300A， m_{O_2} 从大约 1.4×10^{-3} kg 变到 1.3×10^{-3} kg 左右，可以满足燃料电池堆对氧气的需求。从图 3.9 可以看出，当风机转速为 3000rpm 时，随着电流从 200A 跳变到 300A， m_{O_2} 从大约 1.3×10^{-3} kg 变到 1.1×10^{-3} kg 左右，难以满足燃料电池堆对氧气的需求。




图 3.7 阴极气体压力变化图




图 3.8 转速为 3500rpm 时 m_{O_2} 变化图




图 3.9 转速为 3000rpm 时 m_{O_2} 变化图

从以上仿真结果来看，仿真结果和实际实验测试结果一致。这表明本书所建立的模型是正确的，可以精确反映燃料电池堆的动态变化趋势。

下面分析 k_{out} 对系统动态性能的影响。通过第 2 章 k_{out} 计算公式可以看出， k_{out} 可以看做空气回流管道的阻力的倒数， k_{out} 越大，通过回流管道回到大气的流量就越大，反之亦然。当 $k_{\text{sm}}=2\times 10^{-3}$ ， $k_{\text{rm}}=2\times 10^{-3}$ ，风机转速为 3500rpm，输出电流为 200A 时，不同 k_{out} 取值对阴极氧气质量的影响如图 3.10 所示。从图 3.10 可知， k_{out} 的值越小，则阴极氧气质量 m_{O_2} 越大，这是因为 k_{out} 的值小，未反应完的氧气从回流管腔排入空气的少，则留在阴极的氧气就多。但 k_{out} 的值不能过小， k_{out} 的值过小会导致阴极中的废气（氮气）不能及时排出，阴极压力过高，新鲜空气不能进入燃料电池堆，从而造成燃料电池堆缺氧。通过以上仿真可对燃料电池堆的阴极结构设计提供帮助。




图 3.10 不同 k_{out} 下 m_{O_2} 变化图

当 $k_{sm}=2\times 10^{-3}$, $k_{out}=0.5\times 10^{-4}$, $k_{tm}=2\times 10^{-3}$, 燃料电池堆电流有跳变, 0~5 秒电流为 200A, 5~10 秒电流为 300A; 风机转速随着电流的变化进行相应的调整, 0~5 秒风机转速为 3000rpm, 5~10 秒为 3500rpm 时, 阴极氧气质量 m_{O_2} 随时间的变化如图 3.11 所示。仿真结果表明, 此时阴极氧气质量的变化比较平稳, 风机转速随电流的变化进行相应调整可以给阴极提供足够的氧气供应, 又可以节省电力消耗。






图 3.11 风机转速随电流变化时 m_{O_2} 变化图

下面对影响燃料电池水管理的各种因素进行动态分析和仿真。通过对水平衡方程的分析可知, 电堆中参数 k_{out} 、进堆空气流量、喷射的水量及电堆电流对阳极和阴极的水浓度有很大影响, 下面就对这些影响因素逐个进行分析。首先分析参数 k_{out} , 通过第 2 章 k_{out} 计算公式可以看出, k_{out} 可以看做空气回流管道的阻力的倒数, k_{out} 越大, 通过回流管道回到大气的流量就越大, 反之亦然。 k_{out} 不仅对空气供应子系统有很大影响, 而且对阴极和阳极的水浓度有很大影响。不同 k_{out} 情况下阴极和阳极水质量的变化如图 3.12 所示, 其中图 3.12 (a) 为阴极水质量的变化, 图 3.12 (b) 为阳

极水质量的变化。从图 3.12 可以看出, k_{out} 越大, 阴极和阳极水的质量就越小, 这说明 k_{out} 大, 则从阴极回流到空气的水蒸气多, 从而留在阴极的水相应减少。而且从图中可以看出, 当 k_{out} 等于 0.25×0.0001 时, 阴极水的质量呈线性增加, 这说明当 k_{out} 小于一定的值时, 阴极中的水失去平衡, 在阴极管腔中积聚起来 [54]。



(a) 阴极



(b) 阳极

 图 3.12 k_{out} 对阳极和阴极水质量的影响


空气中的水蒸气含量较高,但比燃料电池堆内的湿度要低,所以风机鼓入的空气流量对电堆中水的浓度有一定的影响。不同的空气流量情况下阴极和阳极水质量的变化如图 3.13 所示,其中图 3.13 (a) 为阴极水质量变化图,图 3.13 (b) 为阳极水质量变化图。从图 3.13 可以看出,空气流量越大,阴极和阳极水的质量越小,这是因为回流空气带走的水蒸气量大于鼓入电堆空气中的水蒸气量;当空气流量为 0.15kg/s 时,阴极水的质量呈线性增加,这是因为此时鼓入的空气量不足,导致阴极管腔中的氧气和氮气含量都不足,从而导致阴极管腔的压力不足,使回流的空气流量较小,回流空气携带的水蒸气的总量也就相应较小,最终使阴极中的水失去平衡,水在阴极管腔中积聚起来。

从阴极喷射进电堆的加湿水的流量对电堆中水的浓度有较大的影响。喷射水的流量对阴极和阳极水质量的影响如图 3.14 所示,图 3.14 (a) 为阴极水质量变化图,图 3.14 (b) 为阳极水质量变化图。从图 3.14 可以看出,喷射水的流量越大,则阴极水的质量越大,这和常识相符;当喷射水的流量越来越大,达到一定的阈值时,阴极中的水失去平衡,水在阴极管腔中积聚起来,在图 3.14 中当喷射水的流量为 0.015kg/s 时,阴极水的质量呈线性增加。


燃料电池在反应过程中要生成水,而生成水的多少与电堆电流密切相关,下面分析电流对阴极和阳极水质量的影响。图 3.15 显示了不同电流条件下阴极和阳极水质量的变化,图 3.15 (a) 为阴极水质量变化图,图 3.15 (b) 为阳极水质量变化图。从图 3.15 中可以看出,电流分别为 0A 、 100A 和 200A 时,阴极水的质量略有增加,这说明在其他条件(如电堆结构和空气流量)取得比较合适的情况下,电流的变化对阴极水浓度的影响不大;但当电流为 280A 时,阴极中的水失去平衡,阴极水的质量呈线性增加,这说明在电堆电流较大的情况下,反应生成的水太多,通过空气不能将其吹出电堆,从而在电堆中积聚起来。

从图 3.12~图 3.15 中可以看出,阳极水的质量和阴极水的浓度密切相关,这说明从阴极传递到阳极的水流量较大,可以保证

阳极在较好的湿度条件下工作，同时说明只在阴极加湿是可行的。




(a) 阴极




(b) 阳极

图 3.13 空气流量对阴极和阳极水质量的影响



(a) 阴极



(b) 阳极

图 3.14 喷射水的流量对阳极和阴极水质量的影响





图 3.15 电流对阳极和阴极水质量的影响

从图 3.12~图 3.15 中还可以看出, 阳极和阴极水的动态响应时间很短, 都小于 0.5 秒, 这说明流体在电堆中流动所需时间较

短，没有较大的滞后，这对设计燃料电池系统控制策略很有帮助。

第2章对质子交换膜中水分布做了详细描述，下面分析 k_{out} 、空气流量和喷射水的流量对膜中水分布的影响。从第2章中质子交换膜中水分布的公式可以看出，参数 k 、 β_1 和 β_2 对膜中水分布有很大影响，文献[2]对此做了详细的分析，在此不再详述，本书取 $k=0.001$ ， $\beta_1=\beta_2=0.6$ 进行讨论。图3.16给出了在不同 k_{out} 情况下，质子交换膜厚度的中点处水的浓度随时间变化的情形；图3.17给出了在不同进堆空气流量情况下，质子交换膜厚度的中点处水的浓度随时间变化的情形；图3.18给出了在不同喷射水的流量情况下，质子交换膜厚度的中点处水的浓度随时间变化的情形；图3.19给出了在不同电堆电流情况下，质子交换膜厚度的中点处水的浓度随时间变化的情形。从图3.16～图3.19可以看出，质子交换膜厚度的中点处水的浓度与阳极和阴极的水浓度密切相关，一般在15～20秒之间，膜厚度中点处水的浓度达到稳定。和文献[2]相比，本仿真中膜厚度中点处水的浓度达到稳定的时间要比文献[5]大，这是因为文献[2]将 D 的值固定为 1.25×10^{-5} ，而本仿真中 D 和 n_d 的值随阳极和阴极水浓度的变化而变化，这更符合实际。




图 3.16 k_{out} 对膜中水的浓度的影响




图 3.17 进堆空气流量对膜中水的浓度的影响




图 3.18 喷射水的流量对膜中水的浓度的影响




图 3.19 电堆电流对膜中水的浓度的影响

3.4 小 结

本章开发了燃料电池系统模拟仿真软件，该软件包括输入界面、Simulink 模型和输出界面三部分，可以方便地对燃料电池系统进行仿真。利用此燃料电池系统模拟仿真软件对影响燃料电池系统动态性能的各种因素进行了动态分析和仿真，为设计燃料电池系统控制方法打下了坚实的基础。

第 4 章 质子交换膜燃料电池

空气供应系统控制

质子交换膜燃料电池的空气供应系统是燃料电池堆中重要的组成部分，风机消耗的能量占整个辅助系统所消耗能量的大部分。电堆中阴极氧气的流量需要精确控制，氧气的流量过低，会使燃料电池堆供氧不足，从而降低堆的输出电压，即产生“挨饿”现象；但阴极氧气的流量超过一定限度后，不会提高堆的输出电压，如果继续加大氧气流量，会使风机消耗的功率增大，使整个电堆的净输出功率（电堆输出功率减去电堆辅助装置消耗功率）减小。本章对空气供应系统的控制进行研究，以达到既能满足电堆氧气需要，又能降低风机所消耗能量的控制目标。

4.1 空气供应系统模型

空气供应系统如图 4.1 所示，主要包括风机、供应管腔、阴极和回流管腔 4 个部分。图 4.1 中将多个单片燃料电池阳极和阴极的流道体积分别集总为一个整体，即电堆阳极体积和阴极体积；同样，将各单电池阳极的供应和回流管腔分别集总为阳极供应管腔和阳极回流管腔；阴极的供应管腔包括了阴极流道与管道相连的部分及管道与压缩机相连的部分，阴极回流管腔集总了空气流出阴极的管道。系统的工作原理为：空气通过风机鼓入供应管腔，进入阴极；氢气瓶中的氢气在压力作用下进入阳极，在催化剂层氢气分子分解成质子和电子，氢气质子在电迁移作用下穿过质子

交换膜到达阴极，在阴极催化剂层和氧气分子作用生成水，同时产生电能；在阴极没有反应完的空气通过回流管腔排入大气。空气供应系统的模型可以在第2章建立的燃料电池系统模型，以及第3章燃料电池系统模拟仿真软件的基础上，通过将空气供应系统不相关的变量固定的方式得到。




图 4.1 空气供应系统示意图

4.2 PEMFC 空气供应系统控制国内外研究现状

将空气供应系统作为一个专门的子系统进行研究，国外开始得比较早。美国能源部（DOE）从1998年起就开始资助燃料电池空气供应系统的研究和开发，分别制定了80kW燃料电池空气供应系统的空压机带膨胀机和不带膨胀机时，预期到2010年将达到的目标雷达图，其对80kW燃料电池空气供应系统空压机所要达到的目标进行了全方位规划，包括带膨胀机时空压机的工作参数和不带膨胀机时空压机的工作参数，从输入功率、成本、重量、体积、

辅助系统的工作效率、总输出效率、噪声到动态响应等方面，分别设定了 2005 年和 2010 年预期达到的目标。

我国对燃料电池空气供应系统也进行了相关研究。2004 年，清华大学的杨武^[55]对 PEMFC 空气供应系统的结构模型进行了研究，基于 PEMFC 空气供应系统的功耗分析，提出了采用两种空气系统能量回收方案来提高燃料电池的效率，并利用仿真技术对两种方案的方法和效果进行了比较^[56]。杨武等^[55]研究认为，燃料电池系统结构的复杂性是导致系统集成后效率过低的主要原因，燃料电池堆本身的效率很高，理论值可达 83%，实际情况下可达 60%，加入各个子系统后的输出效率大幅降低，空气系统的功耗可达整个电池堆输出功率的 20% 甚至更多，燃料电池动力系统存在同样的问题。他们在 863 计划燃料电池城市客车项目的开展过程中，发现影响燃料电池动力系统效率的主要问题有两方面，一方面来自燃料电池系统，其中的空气系统功耗过大；另一方面来自动力系统部件，大功率 DC/DC 变换器不仅功率损失较大，影响整车动力系统效率，而且具有容易过热、电磁干扰严重的缺点，影响系统安全性和可靠性。

空气参数，如空气流量、空气压力、空气温度及湿度等，也会对 PEMFC 的输出性能产生直接的影响。例如，空气供给系统的响应速度会影响 PEMFC 的效率、性能和寿命，甚至会因负载功率需求加大而空气供给不足，损坏燃料电池^[57]。国内外在空气参数对燃料电池性能的影响方面也做了一些研究。

Akira Taniguchi 等^[58]和 J T Pukrushpan 等^[59]研究了氧缺乏状态，对质子交换膜燃料电池系统性能的影响。而 M Fournier 等^[60]则研究了在氧富余状态下，质子交换膜燃料电池的工作状况。秦敬玉等^[61]以一个 2kW 氢空质子交换膜燃料电池堆以及由此组成的发动机台架为研究对象，探讨了过量空气系数改变所导致的燃料电池堆和发动机输出特性的变化。结果表明，增大过量空气系数可提高电堆性能，但当过量空气系数增大到 3.0 左右时，电堆

性能随过量空气系数增加的速度明显减小,说明空气流量存在最佳值。孙红等^[62]在实验条件下增大空气流量,燃料电池的性能可持续升高;而增大氢气流量,电池的性能先提高,流量达到一定值后,性能几乎不变,表明在实验条件下,氢气流量存在最佳值;同时分析了背压对 PEMFC 性能的影响,得出升高电池背压,PEMFC 的性能得到提高的结论。

简弃非等^[63]对质子交换膜燃料电池运行参数进行了仿真优化,提出在 PEMFC 正常工作允许的范围内,提高工作压力有利于改善电池的性能,且压力升高对电池性能的影响在低压段增幅较大(高达 1.89%),而在高压段增幅较小(低至 0.6%)。王金龙等^[64]分析了影响车用质子交换膜燃料电池性能的诸因素,建立了 PEMFC 输出电压模型,分析了影响 PEMFC 输出电压和工作效率的主要因素。对 PEMFC 的理论建模与实验研究的结果表明,PEMFC 的输出电压与电堆温度、反应气压力和气体增湿温度有关,在 PEMFC 工作温度和反应气允许压力的范围内,这 3 个因素增大均可使电池电压上升,且反应气压力增大,电堆工作效率提高。张连洪等^[65]研究了温度、压力和湿度对 PEMFC 堆电效率的影响,也得出反应气压力增加,PEMFC 堆电效率提高的结论。赵奕磊等^[66]通过对 5kW 氢空 PEMFC 的性能进行分析,同样得出 PEMFC 性能随着气体压力和电堆温度的升高而提高的结论。可见,提高反应气体压力,PEMFC 的性能和效率均会随之提高。PEMFC 在较高压力下工作时,可以增大燃料电池系统的能量密度,减小系统尺寸,提高电池堆效率和改善水平衡,有利于燃料电池性能的改善。但是受电堆密封要求、材料的强度及反应安全性所限,从系统优化角度出发,燃料电池的工作压力又不宜过大,且空气压缩机作为提供高压氧气的来源也要消耗功率。

D T Santa Rosa 等^[67]研究了在环境压力和温度不变的条件下,提高质子交换膜燃料电池堆工作性能的方法,而 Seong Uk Jeong 等^[68]则研究了在相对湿度不变的条件下,阴极的空气流量对质子

交换膜的影响。许思传等^[69]研究了燃料电池测试平台空气系统的控制算法,建立了空气子系统的温度控制模型和湿度控制模型,目的是获得最佳的空气温度和湿度,使系统调整时间最短。而空气温度与燃料电池堆温度直接耦合,对空气温度的控制,必然涉及水热平衡。关于水热管理系统的控制,谢晋等^[70]研究了温度和湿度对质子交换膜燃料电池的影响。J J Baschuk 等^[71]建立了质子交换膜燃料电池水流量变化时的动态模型,而 Dongmei Chen 等^[72]则建立了质子交换膜加湿子系统的模型并进行了仿真。Jong Hoon Jang 等^[37, 73]建立了质子交换膜燃料电池的水热管理系统模型。在上述模型的基础上, Sun Hong 等^[74~77]研究了水热管理系统中的水传输特性及其瞬态响应。Y M Ferng 等^[78~79]研究了水热管理系统的控制算法。

PEMFC 实质上是一种特殊的电化学反应过程。PEMFC 控制属于复杂工业过程控制,其控制具有多输入/多输出的强非线性、时变性、分布参数特性和强耦合性、大滞后性和约束性、不确定性和随机干扰等特点,为使系统得到实时控制,研究者们提出了各种控制策略。

Phatiphat Thounthong 等^[80~81]对燃料电池发电系统的控制算法进行了研究。A Azmy 等^[82]提出了一种基于人工神经网络的方法,用来在线更新参数,以实现优化管理和简化管理过程。Abtahi H 等^[83]采用模糊控制对水热系统进行控制。Yingfei Xiong 等^[84~85]针对一种小型电池,分析了电池堆阴极的流量和压力模型,并在此基础上进行控制。Fucheng Wang 等^[86~87]分别提出燃料电池的多变量鲁棒控制和模糊控制。L C Iwan 等^[88]利用 CMAC 神经网络前馈控制和传统的 PID 闭环反馈实现了车用燃料电池燃料处理器的智能控制。A P E Atmeid 等^[89]提出了一种神经优化控制系统,采用参数化小脑神经模型控制器来控制系统的输出电压。S Dutta 等^[90~91]分别用神经网络预测燃料电池阳极和阴极之间的质子交换质量,采用神经网络对流量进行实时控制。Yoon-Ho 等^[92~93]采用模糊控制技术,基于电力模

型,控制燃料电池发电量。Cai KaiLong 等^[94]对燃料电池的气压伺服装置进行了研究。Yee-Pien Yang 等^[95~96]分别研究了燃料电池的神经网络自适应控制模型。

上海交通大学在燃料电池的温度建模及控制方面做了研究。Zhi-Jun Mo 等^[97~98]为提高 PEMFC 的性能,采用遗传算法进行优化设计,并进行了模糊控制器的设计与仿真。Y D Tian 等^[99]对燃料电池作为移动电源使用时,提出了自适应模糊控制的方法。另外,为对电堆温度进行实时控制,田玉冬等^[100~101]通过分析 PEMFC 移动电源温度分布参数的特性,采用多变量模糊推理和模糊逻辑控制理论建立了燃料电池温度模糊控制系统。邵庆龙等^[102]避开电堆内部的复杂传热过程,基于能量守恒建立了在大范围的负载扰动下电堆温度的非线性模型,再依据最优控制理论设计了保证电堆温度恒定的非线性控制器。李曦等^[103~104]采用模糊聚类 and 线性辨识方法在线建立 PEMFC 电堆工作温度的 T-S 模糊预测模型,然后基于分支定界法的基本原理对控制量进行离散寻优,从而实现 PEMFC 的非线性预测控制。

武汉理工大学在 PEMFC 冷却系统和发动机系统控制方面也做了研究。向金凤、全书海等^[105]针对质子交换膜燃料电池冷却系统的复杂性,提出了一种适合燃料电池冷却系统的 Fuzzy-PID 控制器复合控制系统。实验证明该控制系统能比普通 PID 控制器更好地自动适应燃料电池复杂环境的变化。全书海等^[106]针对燃料电池发动机受控过程复杂的特点,提出了一种分解—协调控制策略,采用逆奈氏阵列法(INA)进行控制系统设计,并投入实际运行中,获得了较好的控制效果。阮诗峰等^[107]提出了可软配置燃料电池发动机控制系统的方案,引入了可软配置升级和多性能协调控制策略的思想,对控制系统进行了设计和分析,重点对燃料电池发动机控制器可软配置升级机制进行了研究,并阐述了多性能协调控制策略的应用。

上述控制策略的研究虽然取得了较好的控制效果,但是其研

研究对象主要集中在直接影响 PEMFC 正常工作的温度和水热管理系统方面,对电动汽车实际运行时,与其负载变化直接相关的空气供应系统则研究得很少。

通过对空气供应系统研究现状的分析,将目前存在的主要技术问题归纳如下^[108]。

① 从空气参数对系统性能的影响来看,大多数研究对象非常具体,只针对某个功率的燃料电池在实验条件下,分别分析了空气流量、空气压力、空气温度及湿度的改变而引起的空气参数变化对系统性能的影响。这些结论是在稳态条件下得出的,对燃料电池动态变化过程未作进一步分析、研究。

由于电动汽车实际运行时的环境和条件远比实验室复杂,当电动汽车在起动、加速、巡航、减速、刹车等工作状态时,PEMFC 的工作负荷变化很大,导致空气需求量变化大。目前,根据实际负载对空气流量的动态需求,对空气供应系统进行实时动态调节,优化空气流量,提高效率,降低 PEMFC 系统的寄生功耗,减小辅助储能装置的体积等方面的研究还处于初级阶段。

② 从建模方面来看,由于 PEMFC 系统工作在封闭、复杂的环境下,并具有多回路、多相流循环的电化学反应,是一种多输入/多输出的非线性系统,各国学者主要对 PEMFC 的数学模型进行了广泛而深入的研究,但研究多集中在 PEMFC 系统级的建模和控制,以及物料传递与传质、水/热平衡模型的分析与控制等影响 PEMFC 系统本体的安全和质子交换膜工作性能及使用寿命的方面。虽然有些学者采用神经网络的方法建立了燃料电池模型,仿真结果表明能很好地拟合系统的输出特性,但从目前已有的燃料电池模型来看,有些模型对燃料电池核心组件的分析和建模比较深入,有些对燃料电池电堆的分析和建模比较深入,但绝大多数燃料电池模型都没有将燃料电池堆和输出功率的变化结合起来,没有综合考虑负载动态变化时控制系统模型的改变。若要延长燃料电池在电动汽车上的使用寿命,必须进一步考虑负载的实时需求,对空

气供应系统及时调节,使燃料电池处于最佳运行状态。

③ 从控制方面来看,燃料电池系统的控制极其复杂,目前发展趋势是从简单的PID控制向智能控制的方向发展。在燃料电池的智能控制方面,各国学者已经展开研究,但是研究的对象主要是燃料电池堆,控制量为温度、燃料气体流量或加湿量,并且大多是对燃料电池稳态下的控制,没有考虑负载变化的情况。提高燃料电池空气供应系统的动态响应时间,从而减小辅助装置的体积和重量是当前研究的难点,也是影响燃料电池电动汽车推广应用的一个关键问题。在汽车启停频繁及瞬时加速等工况下,因为功率需求较大而燃料供给不足时,燃料电池发动机就会处于过载状况,这时,将会导致电极活性下降,甚至引起电池组失效。至于提高车载燃料电池运行时的效率,提高路面的适应性等方面的建模和控制策略的研究才刚刚起步。

4.3 PID 控制

针对燃料电池系统的原理和特点,首先采用传统的PID控制方法对燃料电池空气供应系统进行控制。

4.3.1 PID 控制算法

PID控制是控制系统中应用最广泛的控制规律,能很好地消除误差、克服振荡,具有稳定性高、动态响应快等优点,而且控制参数相互独立,参数整定非常方便,其控制规律为:

$$u(t) = K_p[\alpha(t) + \frac{1}{T_I} \int_0^t \alpha(t) dt + T_D \frac{d\alpha(t)}{dt}] \quad (4.1)$$

对应的模拟PID控制器的传递函数为:

$$G(s) = K_p \left(1 + \frac{1}{T_i s} + T_d s \right) \quad (4.2)$$

式中, K_p 为比例增益, T_i 为积分时间常数, T_d 为微分时间常数, $u(t)$ 为 PID 控制器的输出, $e(t)$ 为控制系统的输入量与输出量之差。由于在计算机控制系统中 PID 控制规律的实现必须用数值逼近的方法, 所以要将模拟 PID 离散化, 可得如下差分方程:

$$u(k) = K_p \left[e(k) + \frac{T}{T_i} \sum_{i=0}^k e(i) + T_d \frac{e(k) - e(k-1)}{T} \right] \quad (4.3)$$

其中 K_p 、 T_i 、 T_d 的整定有比较成熟的方法, 可以采用先比例、后积分、再微分的试凑法来确定。

4.3.2 控制方法实现

在 PEMFC 空气供应系统中, 为了保证燃料电池电堆中氧气供给的连续性, 及电堆内电化学反应的连续性, 要不断提供一定压力、流量的良好滤清空气, 这是通过高速风机向燃料电池电堆内鼓入空气来实现的。在燃料电池实际工作时, 供应管腔的压力易于检测, 故确定 PID 控制器的输入量为供应管道的压力差值 e , 控制器输出量为风机的电压 u , 则控制框图如图 4.2 所示。




图 4.2 燃料电池空气供应系统 PID 控制框图

PEMFC 空气供应系统是一个多输入/多输出控制系统, 这里重点研究较难控制的供给管道压力, 则系统输入的参考值为供给管

道压力给定值 p_{sm} ，输出为风机管道的实际压力 p_c （ p_c 是通过供给管道上的压力传感器采集到的），两者进行比较，得出压力差值 e ，经过 PID 运算调节处理得出准确的风机电压值 u ，从而通过改变风机电压值来控制进入电堆内气体的压力值，达到控制电堆内氧气量的目的。

4.3.3 PID 控制仿真结果及分析

将控制模型在 Simulink 下进行仿真，可得输入管道压力 p_{sm} 在 4s 内的响应曲线图，如图 4.3 所示。




图 4.3 p_{sm} 在 4s 内的响应曲线图

由图 4.3 可以看出，供给气体压力的 PID 控制响应时间非常短，约 0.38s 左右 p_{sm} 就达到平衡值 1.3×10^5 Pa，很好地减小了误差，达到稳定后几乎消除了振荡；当 $t=2$ s，电流由 $I_{st}=160$ A 增大到 200A 时，通过 PID 控制器的作用，加大风机的控制电压，风机

的流量增加,从而使 p_{sm} 瞬间有个突降后马上回到稳定值,保证了电堆内氧气的供应,达到了很好的控制效果。

空气供给管道气体压力的PID控制器是一种按当前偏差确定控制量的线性调节器,其优点是简单且鲁棒性强。但它也存在着一些缺点,如非线性、不确定性,往往不能保证良好的调节品质。在静态精度和动态稳定性能及响应快速性和平稳性两方面,也只能折中处理。而且从图4.3可以看出,PID控制的响应时间大约为0.5秒,在燃料电池系统这样一个采样时间短的发电系统中,响应时间不能满足要求。

4.4 PEMFC 空气参数解耦设计

PEMFC 的空气参数是强耦合、时变、非线性变量,应根据多变量过程控制系统的解耦理论^[115],进行空气参数的解耦设计,以便各空气供给控制系统独立运行,彼此不受或少受其他参数的影响。车用 PEMFC 运行时,空气流量、空气压力和空气温度相互关联,相互影响。在空气压力、空气流量和空气温度的动态变化过程中,由于空气作为燃料,不断地被消耗、被补充,因此,不适用理想气体状态方程,且各参数之间是非线性关系,为了对空气控制回路进行有效控制,对空气参数进行解耦是必要的。

本书中对空气参数的解耦设计,仅考虑空气流量和空气压力的解耦。至于空气温度的控制,由于它与燃料电池堆工作温度直接耦合,而在燃料电池水热管理系统中,关于燃料电池堆工作温度的控制策略研究已有详细论述,这方面的文献非常多,并有很多成熟的控制方案,因此这里对空气温度的控制不再展开进一步的研究。

4.4.1 多变量过程控制系统解耦理论

工程界和理论界一致认为,多变量控制系统是高级而又复杂的过程控制系统。从控制理论的观点看来,高级和复杂意味着这种控制系统能满足一些更高的控制要求或者控制指标,从而在理论分析的深度与广度上,都超过了常规的单变量过程控制理论,因此,从20世纪60年代以来,多变量过程控制理论受到了广泛的关注,并且很多研究结果已被成功地应用于实践^[109]。

目前,多变量过程控制系统的解耦理论已成为过程控制理论中的一个重要领域,而且,就其内容的深度而言,人们也普遍认为,它是过程控制理论中最难的理论领域之一。多变量过程控制的内容很多,在多变量过程控制理论与实践中,有一个突出的问题是研究如何实现解耦控制,也就是讨论采取何种措施,能够把一个有耦合影响的多变量过程,化为一些无耦合的单变量过程来处理,或者经过理论分析与判断,可以允许一定程度的耦合影响存在,这样就可以用单变量系统理论来处理了,处理这样的理论问题,就称为多变量过程控制系统解耦理论^[109]。

Kavamgh 等将 Boksenbom、Hood 和钱学森首先提出的根据不相干控制原则设计的矩阵分析法理论应用于过程控制系统,其基本思想是进行适当的设计,使联系多变量控制系统输入变量与输出变量的系统传递函数矩阵成为一个对角矩阵,一般称之为对角矩阵法。

多变量过程控制系统有很多种解耦方法,除对角矩阵法外,还有状态变量法、反 Nyquist 曲线法等。至于选用哪一种解耦方法,则要根据研究对象和研究目的来确定。现代控制理论家都十分欣赏状态变量法,对于变量数目相当多的高阶大系统,适宜用此方法进行理论上的分析,其研究的对象常常是抽象化了的;然而过程控制理论家及工程师们却格外喜欢对角矩阵法,因为它能

十分方便地应用于多变量过程控制系统的解耦设计，而且由此引出来的结论都能很容易地在实际中得到应用，所以它成为工程实践中应用最广的方法。状态变量法目前在过程控制实践中应用不多，而反 Nyquist 曲线法及特征曲线法虽然能应用于实践，但 these 方法本身引用的理论概念很多，计算也较复杂，因此应用起来也不甚方便，这就限制了它们的流行^[109]。

本书中对空气流量、空气压力进行解耦设计，主要是为了满足车用 PEMFC 空气供应系统的实际需要，因此选用对角矩阵法，对空气流量、空气压力进行解耦设计。

4.4.2 PEMFC 空气参数解耦设计

在 PEMFC 空气供应系统双回路控制中，空气流量和空气压力是具有非线性、时变性和强耦合性的变量。为使空气流量控制回路和空气压力控制回路单独作用，对空气流量和空气压力这两个强耦合的空气参数进行解耦设计。

1. 解耦设计原理

车用 PEMFC 空气流量和空气压力这两个强耦合的空气参数双变量解耦控制系统包括两个回路，即空气流量控制回路和空气压力控制回路。空气参数双变量解耦控制系统如图 4.4 所示^[110]。

在空气供应系统的空气参数双变量解耦控制系统中，设被控变量为空气流量 y_1 和空气压力 y_2 ，控制变量为空压机转速 u_1 和背压阀开度 u_2 ，控制器输出分别为空气流量调节量 u_{c1} 和空气压力调节量 u_{c2} ，空气流量给定值为 r_1 ，空气压力给定值为 r_2 。 $G_{11}(s)$ 、 $G_{22}(s)$ 、 $G_{21}(s)$ 、 $G_{12}(s)$ 分别为被控回路和耦合回路的传递函数， $D_{11}(s)$ 、 $D_{22}(s)$ 、 $D_{21}(s)$ 、 $D_{12}(s)$ 均为解耦器。

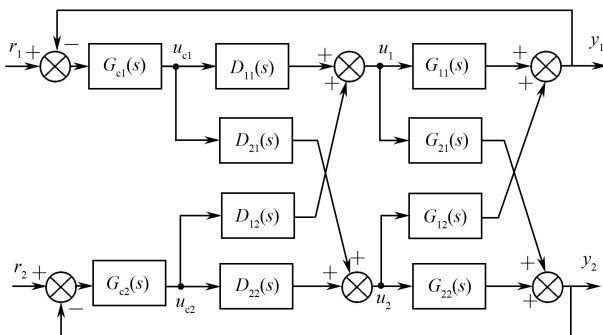


图 4.4 空气参数双变量解耦控制系统

空气供应系统的被控变量与控制变量之间的矩阵可表示为：

$$\begin{bmatrix} Y_1(s) \\ Y_2(s) \end{bmatrix} = \begin{bmatrix} G_{11}(s) & G_{12}(s) \\ G_{21}(s) & G_{22}(s) \end{bmatrix} \begin{bmatrix} U_1(s) \\ U_2(s) \end{bmatrix} \quad (4.4)$$

控制变量与调节器输出之间的矩阵为：

$$\begin{bmatrix} U_1(s) \\ U_2(s) \end{bmatrix} = \begin{bmatrix} D_{11}(s) & D_{12}(s) \\ D_{21}(s) & D_{22}(s) \end{bmatrix} \begin{bmatrix} U_{c1}(s) \\ U_{c2}(s) \end{bmatrix} \quad (4.5)$$

将式 (4.5) 代入式 (4.4)，得到系统的传递矩阵为：

$$\begin{bmatrix} Y_1(s) \\ Y_2(s) \end{bmatrix} = \begin{bmatrix} G_{11}(s) & G_{12}(s) \\ G_{21}(s) & G_{22}(s) \end{bmatrix} \begin{bmatrix} D_{11}(s) & D_{12}(s) \\ D_{21}(s) & D_{22}(s) \end{bmatrix} \begin{bmatrix} U_{c1}(s) \\ U_{c2}(s) \end{bmatrix} \quad (4.6)$$

欲使传递矩阵为对角阵，则得解耦器的数学模型为：

$$\begin{aligned} \begin{bmatrix} D_{11}(s) & D_{12}(s) \\ D_{21}(s) & D_{22}(s) \end{bmatrix} &= \begin{bmatrix} G_{11}(s) & G_{12}(s) \\ G_{21}(s) & G_{22}(s) \end{bmatrix}^{-1} \begin{bmatrix} G_{11}(s) & 0 \\ 0 & G_{22}(s) \end{bmatrix} \\ &= \frac{1}{G_{11}(s)G_{22}(s) - G_{12}(s)G_{21}(s)} \begin{bmatrix} G_{11}(s)G_{22}(s) & -G_{12}(s)G_{22}(s) \\ -G_{21}(s)G_{11}(s) & G_{22}(s)G_{11}(s) \end{bmatrix} \end{aligned} \quad (4.7)$$

显然，用式 (4.7) 中的解耦器进行解耦，将使被控变量空气流量 y_1 不受空气压力调节量 u_{c2} 的影响；同样，空气压力 y_2 也不受空气流量调节量 u_{c1} 的影响。空气流量控制回路和空气压力控制回

路径解耦器解耦后，变成两个完全独立的控制回路。

用相对增益表示式 (4.7)，则解耦器的数学模型为：

$$\begin{bmatrix} D_{11}(s) & D_{12}(s) \\ D_{21}(s) & D_{22}(s) \end{bmatrix} = \frac{1}{k_{11}g_{11}k_{22}g_{22} - k_{12}g_{12}k_{21}g_{21}} \times \begin{bmatrix} k_{11}g_{11}k_{22}g_{22} & -k_{12}g_{12}k_{22}g_{22} \\ -k_{11}g_{11}k_{21}g_{21} & k_{11}g_{11}k_{22}g_{22} \end{bmatrix} \quad (4.8)$$

2. 相对增益计算

对多变量控制系统进行分析或整定，首先要计算其开环增益。对于具有两个被调量和两个调节量的分析或整定过程，需要考虑 4 个开环增益。尽管从外表上看，只有两个增益闭合在回路中，但是，还必须就如何匹配做出选择。利用相对增益作为衡量多变量性能尺度的方法，被称为布里斯托尔-欣斯基方法^[11]。

对于车用 PEMFC 空气供应的多变量系统，假设 y 是包含系统所有被调量 y_i ，即空气流量和空气压力的列向量； u 是包含所有调节量 u_j ，即空压机转速和排风量的列向量。为了衡量系统的关联性质，首先在另外一个回路为开环，即其调节量保持不变的情况下，得到车用 PEMFC 空气供应系统的开环增益矩阵 P ，记为：

$$y = Pu \quad (4.9)$$

其中，矩阵 P 的元素 p_{ij} 的静态值称为 u_j 到 y_i 通道的第一放大系数。它是指空气供应系统的调节量 u_j 改变了一个 Δu 时，另一个调节量 u_r ($r \neq j$) 不变的情况下， u_j 与 y_i 之间通道的静态增益， p_{ij} 可表示为：

$$p_{ij} = \left. \frac{\partial y_i}{\partial u_j} \right|_{u_r} = k_{ij} \quad (4.10)$$

然后，在所有回路均闭合，即保持其被调量都不变的情况下，找出各通道的开环增益，记为矩阵 Q 。它的元素 q_{ij} 的静态值称为 u_j 到 y_i 通道的第二放大系数。它是指利用闭合回路固定另一个被

调量时, u_j 到 y_i 的开环增益。 q_{ij} 可表示为

$$q_{ij} = \left. \frac{\partial y_i}{\partial u_j} \right|_{y_r} \quad (4.11)$$

有了矩阵 P 和 Q , 取它们相应元素的比值构成新的矩阵 A , 其元素可写为:

$$\lambda_{ij} = \frac{p_{ij}}{q_{ij}} = \frac{\left. \frac{\partial y_i}{\partial u_j} \right|_{u_r}}{\left. \frac{\partial y_i}{\partial u_j} \right|_{y_r}} \quad (4.12)$$

式 (4.12) 即为 u_j 到 y_i 这个通道的相对增益, 矩阵 A 则称为相对增益矩阵。通过计算, 得到车用 PEMFC 空气供应系统的相对增益矩阵为:

$$A = \begin{bmatrix} \lambda_{11} & \lambda_{12} \\ \lambda_{21} & \lambda_{22} \end{bmatrix} \quad (4.13)$$

3. 递推参数模型辨识

根据对角矩阵法, 通过设计解耦器, 可得输入变量与输出变量关系的对角矩阵。但是, 对一个非线性、时变的空气供应系统, 通过机理建模得到空气流量和空气压力的耦合模型, 计算量非常大, 不利于实时控制, 因此, 本节根据实际测试的实验数据, 通过参数模型辨识法建立空气流量和空气压力的参数耦合模型。通过系统参数辨识的方法建立的空气供给控制回路的耦合数学模型, 参数可能不具有明确的物理意义, 但是并不影响利用该模型进行控制系统的设计。本节用扩展自回归滑动平均 (CARMAX) 模型建立空气参数控制回路中的输入/输出参数模型, 其形式如下:

$$A(s)y(t) = B(s)u(t) + C(s)a(t) \quad (4.14)$$

根据车用 PEMFC 在清华大学测试时的实验数据, 通过参数辨

识方法, 可得电动汽车在起步加速阶段的参数辨识模型。通过 MATLAB 对测试的实验数据进行参数辨识计算, 得到空气流量与空压机转速之间、空气流量与排风阀开度之间、空气压力与空压机转速之间、空气压力与排风阀开度之间的传递函数模型, 以及 CARMAX 模型中的参数 $A(s)$ 、 $B(s)$ 、 $C(s)$ 和损失函数、最终预测误差等性能指标。

由于通常用参数模型辨识法建立的空气供应系统模型, 都基于一次完成算法, 是离线辨识的, 而在车用 PEMFC 空气供应控制系统中, 空压机转速和排风阀的开度对 PEMFC 空气流量、空气压力、空气温度的影响同样强烈。当空压机转速增大时, 空气流量增加, 空气压力增大 (当排风阀开度不变时), 由于反应速度加快, 因此空气温度升高 (由水热管理控制系统调节), PEMFC 输出功率增加。当排风阀开度关小时, PEMFC 中空气压力增大, 排出空气流量减小, 因此, 空气带出的水分和热量均减少, 会导致质子交换膜被“水淹”, 且电池堆温度急剧升高, 影响系统的安全运行。反之, 又会导致“干膜”事故的发生, 影响系统的工作效率和寿命。另外, 当 PEMFC 系统运行时, 空气流量、空气压力两个闭环控制回路的给定值随 PEMFC 输出功率的变化而改变, 且由于车用 PEMFC 的输出功率与路况和运行环境直接相关, 实时控制模型处于动态随机变化过程中, 为了得到更好的辨识效果, 本节采用递推参数模型辨识法, 实现车用 PEMFC 空气供应系统的在线实时辨识。

递推辨识法不仅减少了内存用量, 而且能实现在线实时辨识, 递推辨识算法通常具有如下形式:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)(y(t) - \hat{y}(t)) \quad (4.15)$$

式中, $\hat{\theta}(t)$ 为时刻 t 的参数估值, $y(t)$ 为时刻 t 的测量输出, $\hat{y}(t)$ 为时刻 t 根据辨识模型得到的预测输出, $K(t)$ 为辨识增益矩阵。

$K(t)$ 的选取通常为:

$$K(t) = Q(t)\Phi(t) \quad (4.16)$$

式中, $\Phi(t)$ 为 $\hat{y}(t)$ 对于参数 θ 的变化梯度, 即:

$$\hat{y}(t) = \Phi^T(t)\hat{\theta}_0(t) + \alpha(t) \quad (4.17)$$

式中, $\hat{\theta}_0(t)$ 为对象的实际参数向量, $\alpha(t)$ 为噪声。

这里采用的归一化梯度算法的增益矩阵为:

$$Q(t) = \frac{\gamma I}{|\Phi(t)|^2} \quad (4.18)$$

式中, I 为单位阵。

通过 MATLAB 对测试的实验数据进行递推辨识计算, 得到空气流量与空压机转速之间、空气流量与排风阀开度之间、空气压力与空压机转速之间、空气压力与排风阀开度之间的实时传递函数模型。

由式 (4.8) 计算解耦器 $D(s)$ 的传递函数, 从而实现空气流量控制回路和空气压力控制回路的解耦。

通过以上分析可知, 本节对所研究的车用 PEMFC 空气供应系统的控制策略研究是非常必要的。由于车用 PEMFC 空气供应系统的空气流量和空气压力通过不同的执行机构来调整, 一般情况下, 由空气供应控制系统的空气参数给定值预测燃料电池堆输出功率的变化, 因此, 空气流量的控制实时性较强。同时, 空气压力的调整也是通过预测燃料电池堆输出功率的变化而使执行机构动作的, 因此, 空气压力的调整几乎与空气流量的调整同时发生, 至于空气流量变化引起的空气压力波动, 通过系统的微调就可达到较满意的控制效果, 从而实现了空气流量控制回路和空气压力控制回路相对独立的控制。

通过对车用 PEMFC 空气参数的解耦设计, 使空气流量控制回路和空气压力控制回路相对独立。根据多变量过程控制系统的解耦理论, 设计了对角矩阵解耦器, 计算空压机转速—空气流量通道、排风阀—空气压力通道及控制变量耦合通道的相对增益矩阵。

由于车用 PEMFC 空气供应系统的工作参数随燃料电池堆负载功率的变化而实时调整,因此,提出空气供应控制系统的解耦模型采用递推参数辨识法,实时辨识空气供应系统的空压机转速、空气流量通道、排风阀、空气压力通道及控制变量耦合通道模型的参数,建立空气供应系统的实时解耦模型,通过对对角矩阵解耦器的实时计算,可有效解除空气流量控制回路和空气压力控制回路的控制变量耦合,即解除空气流量控制回路中的控制变量空压机转速与空气压力控制回路中的被控变量空气压力的耦合,以及空气压力控制回路中的控制变量排风阀开度与空气流量控制回路中的被控变量空气流量的耦合。

在 PEMFC 空气供应系统中,空气流量的调节是通过改变空压机的转速实现的,空气压力的调节是通过改变排风阀的开度实现的,至于因空压机转速的变化而引起的空气压力的波动和因排风阀开度变化而引起的空气流量的波动,则通过解耦器的设计,使其对另外一个回路被控参数的影响变小,甚至完全抵消彼此的影响。通过对车用 PEMFC 空气参数的解耦设计,使空气流量控制回路和空气压力控制回路独立完成相应的控制功能,达到较好的控制效果。

4.5 空气流量控制策略研究

空气流量不仅影响电池堆的输出功率,还影响质子交换膜的性能。当输出功率减小而空气流量过大时,空气会带走质子交换膜中的大量水分,使质子交换膜干燥,影响质子的传输效果,同时使系统的寄生功耗增加,影响系统的效率。当输出功率增大而空气流量太小时,又会使反应气体加湿过度,阻塞气体扩散电极的微孔,使电极被淹没;同时,氢气与氧气进行电化学反应生成

的水增多，空气流量不足以带走多余的水分，也会使电极被淹没。因此，空气流量必须随输出功率的变化而调节。

4.5.1 控制系统结构

PEMFC 的燃料主要是氢气和空气（氧气）。一般情况下，PEMFC 的氢气供给是充足的，主要通过氢气循环泵，向燃料电池提供足够的氢气，而空气的供给则需要根据负载的大小来实时调节。在 PEMFC 运行时，空气供给的流量及其响应速度对燃料电池系统的效率、性能和寿命等都会产生重要影响。

PEMFC 空气流量控制回路主要由驱动空压机高速旋转的 BLDCM、电机转速检测及变换装置、转速外环的 Fuzzy-PID 复合控制器和电流内环的 PI 控制器、空气流量给定值四大部分组成。空气流量控制方框图如图 4.5 所示。

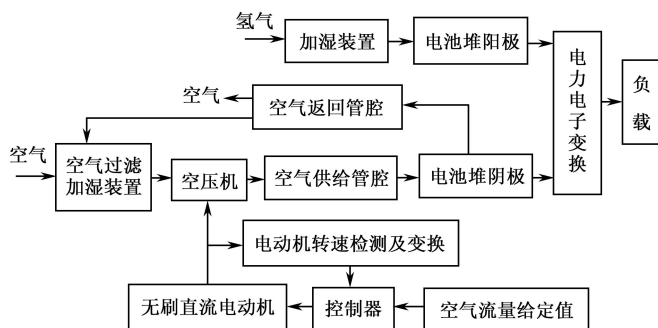


图 4.5 空气流量控制方框图

空气流量给定值由 Elman 神经网络预测模型动态给定。PEMFC 空气流量控制回路与常规 BLDCM 控制系统的最大区别是空气流量给定值是动态的、随机的，它与 PEMFC 系统的负荷变化、输入参数及系统内部的工作状态直接相关。

基于 Elman 动态神经网络的空气流量给定值的预测模型和基于空气流量的控制模型,建立了空气流量控制回路;分析了基于机理模型的空气流量,采用 Fuzzy-PID 复合控制策略和采用单纯的 PID 控制策略时,对控制性能的影响。仿真结果表明,空气流量采用 Fuzzy-PID 复合控制策略较好地改善了控制系统的动态性能,空压机的驱动电机的转速响应时间远远小于采用单纯的 PID 控制策略时的响应时间,且无超调,控制精度高。虽然这种控制策略的适用范围广,但针对具体的电动汽车起步加速阶段研究,其控制性能则显得较弱。为此,针对空气流量的本质非线性特点,分析了基于神经网络辨识模型的空气流量,采用神经 PID 控制策略时,控制系统在模拟电动汽车起步加速阶段时的响应过程。仿真结果表明,空气流量采用神经 PID 控制策略,完全可以跟踪燃料电池堆输出功率的变化。此控制策略针对性较强,但适用范围较小,当使用场合改变时,由于测试数据的改变,使得神经网络的学习时间相应延长,甚至学习失败。可见,这两种控制策略各有利弊,实际使用时,应具体问题具体分析,从而选择合适的控制方式,以满足车用 PEMFC 对空气流量的需求。

4.5.2 空气流量 Fuzzy-PID 复合控制


在 PEMFC 空气流量控制回路中,当空气流量采用 Fuzzy-PID 复合控制策略时,给定值采用 Elman 神经网络预测模型的动态给定值,被控对象为空压机的驱动电机,被控变量为空气流量,控制变量为空压机的驱动电机的转速,控制空气流量快速跟随负荷的变化。

Fuzzy-PID 复合控制通过设定阈值,使控制系统在偏差较大时,采用 Fuzzy 控制,提高系统的响应速度。当偏差位于某一范


围内时,系统控制自动切换至PID控制,以满足系统的精度要求。在控制系统动态响应的过程中,Fuzzy控制和PID控制交替起作用。Fuzzy-PID复合控制与常规PID控制相比,具有动态响应快、上升时间短、控制性能指标好的特点。

Fuzzy控制是模糊理论在控制领域的应用,是一种20世纪90年代兴起的、能够提高复杂工业自动化水平的新型控制技术。Fuzzy控制能够模拟人脑的智能推理过程进行判断和决策控制,它的鲁棒性很强,特别适用于非线性、时变、滞后及耦合系统的控制。由于PEMFC系统的时变性、非线性等特点,其数学模型和控制参数不易精确确定,因此采用Fuzzy控制不但对PEMFC系统的负载扰动具有鲁棒性,而且还能有效地克服电机本身的时变性和非线性等特点。将这种新的智能控制技术应用到PEMFC控制,运用多变量模糊理论,结合PEMFC实验数据和模拟仿真的结论,建立PEMFC正常运行的基本规则,构成其控制知识库。根据负荷条件和PEMFC的各输入/输出参数,经过推理计算获得较精确的控制量,从而得到较好的控制效果。

本节的Fuzzy控制器选用“二输入、一输出”结构,它主要由模糊化、模糊推理、反模糊化和规则知识库4个部分组成。其输入变量是偏差 e 及偏差变化率 ec ,偏差 e 的实际论域范围为 $[-8000, 8000]$,对其进行模糊化,量化到 $[-10, -6, -4, -2, 0, 2, 4, 6, 10]$;偏差变化率 ec 的实际论域范围为 $[-15000, 15000]$,量化至 $[-50, -30, -20, -10, 0, 10, 20, 30, 50]$ 。 e 和 ec 的模糊集均取 $\{NB, NM, NS, ZO, PS, PM, PB\}$,输入变量 e 和 ec 的隶属度函数如图4.6所示。



(a) 变量e



(b) 变量ec

图 4.6 输入变量 e 和 ec 的隶属度函数

模糊化完成对系统变量的模糊划分和对确定输入值的模糊化处理，用模糊集表示实测的输入值。模糊推理是模糊控制的核心，它根据从控制经验和知识中抽象出来的控制规则，用已知的模糊输入量推导出相应的模糊输出，实质上是一种从输入空间到输出空间的非线性映射关系。规则知识库是模糊控制的重要部分，它用来存储系统的基于语言变量的控制规则和系统参数。

规则知识库可用以下 49 条模糊条件语句来描述。

① if $e=NB$ and $ec=NB$ then $ur=PB$

② if $e=NB$ and $ec=NM$ then $ur=PB$

...

④⑨ if $e=PB$ and $ec=PB$ then $ur=NB$

将上述语句制成模糊控制规则表，见表 4.1。

表4.1 模糊控制规则表

$\begin{matrix} \text{ec} \\ \text{e} \end{matrix}$	NB	NM	NS	ZO	PS	PM	PB
NB	PB	PB	PM	PM	PS	PS	ZO
NM	PB	PM	PM	PS	PS	ZO	ZO
NS	PM	PM	PS	PS	ZO	ZO	ZO
ZO	PS	PS	ZO	ZO	NS	NS	NM
PS	PM	PS	ZO	NS	NS	NM	NM
PM	PS	ZO	NS	NM	NM	NB	NB
PB	ZO	NS	NM	NM	NB	NB	NB

反模糊化是将模糊推理推出的模糊控制结果转化为确定的控制量输出值，实现由控制输出模糊量到精确量的转化，以得出用于控制的精确输出量。根据上述模糊规则进行运算，采用加权平均法解模糊即可得控制量 u_r 。控制量 u_r 的实际论域范围为 $[-10, 10]$ ，其隶属度函数如图 4.7 所示。




图 4.7 控制量 u_r 隶属度函数

PID 控制是控制系统的经典控制算法，它以控制作用的快速性、准确性及稳定性而著称。经典增量式数字 PID 控制算式为：

$$u(k) = u(k-1) + K_p[\alpha(k) - \alpha(k-1)] + K_i\alpha(k) + K_d[\alpha(k) - 2\alpha(k-1) + \alpha(k-2)] \quad (4.19)$$

式中, K_p 、 K_i 、 K_d 分别为比例、积分、微分系数。

Fuzzy-PID 复合控制在偏差较大时, 由 Fuzzy 控制对负荷的变化进行快速自适应调整, 使空气流量快速跟随负荷的变化, 以提高控制系统的响应速度, 当偏差位于某一范围内时, 控制系统切换至 PID 控制, 以满足系统的控制精度要求。

PEMFC 空气流量控制的实质是控制高速 BLDCM 的转速, 当由 BLDCM 驱动空压机旋转的转速升高时, PEMFC 的空气流量增加; 反之, 则减少。BLDCM 的转速控制采用转速、电流组成的双闭环调速控制系统。由于车用 PEMFC 的负荷变化是随机的, 要求 PEMFC 空气流量能够在较大范围内变化, 因此 BLDCM 的转速外环采用 Fuzzy-PID 复合控制。当 PEMFC 的负荷变化幅度很大时, 常规的 PID 控制无能为力, 为快速响应负载的变化, 采用 Fuzzy 控制。当偏差在某一范围内时, 利用常规 PID 的优势, 改善控制系统的稳态性能。通过设定偏差阈值, 可有效结合 Fuzzy 控制和 PID 控制的优势, 达到最佳控制状态。

在 MATLAB 命令窗口中, 将经过训练的 Elman 神经网络预测模型加入空气流量控制系统的 Simulink 模型中, 作为空气流量控制回路的给定值。由 BLDCM 的工作参数构成其本体模型, 其转速外环采用 Fuzzy-PID 复合控制, 电流内环采用 PID 控制。利用 Elman 神经网络动态预测空气流量给定值的 PEMFC 空气流量控制仿真模型如图 4.8 所示。






图 4.8 PEMFC 空气流量控制仿真模型

由图 4.8 可知, 燃料电池的输出功率、电池堆温度等参数经归一化处理后, 组成 Elman 神经网络预测模型的输入矩阵 $p\{1\}$, 预测模型的输出矩阵 $y\{1\}$ 为空气流量的归一化数值, 经增益为 10 的模块后, 设定 BLDCM 转速给定值区间为 $[0, 10]$ 。当空气流量给定值预测模型的输入矩阵 $p\{1\}$ 取不同值时, 其输出矩阵 $y\{1\}$ 随之改变, 因而, 空气流量控制回路的给定值发生变化, 从而改变了 BLDCM 的转速, 使得空压机的转速发生改变, 因此, 改变了进入燃料电池堆的空气流量。

对经过训练的 Elman 神经网络预测模型分别输入 3 组测试数据后, 分别采用 PID 控制策略和 Fuzzy-PID 复合控制策略时, BLDCM 转速响应曲线如图 4.9 所示。



(a) PID控制



(b) Fuzzy—PID复合控制

图 4.9 BLDCM 转速响应曲线

由图 4.9 可知, PEMFC 空气流量控制系统仿真模型中, 当 Elman 神经网络预测模型的输入矩阵 $p\{1\}=[0.86; 0.2]$ 时, $y\{1\}=0.2065$, 电机输出转速约为 4000rpm; 当 Elman 神经网络预测模型的输入矩阵 $p\{1\}=[0.80; 0.5]$ 时, $y\{1\}=0.5614$, 电机输出转速约为 8000rpm; 当 Elman 神经网络预测模型的输入矩阵 $p\{1\}=[0.79; 0.9]$ 时, $y\{1\}=0.8339$, 电机输出转速约为 11000rpm。可见, Elman 神经网络预测模型输入矩阵不同, PEMFC 空压机的驱动电机的给定值就不同, 因此, 电机的稳定转速随给定值的不同而变化。随着燃料电池堆输出电流的增大, 即输出功率增加时, 输出电压下降, 空气压力、空气温度、电池堆温度等参数均增大, 电机转速升高, 空压机供给的空气流量也增加。随着电机稳定转速的升高, 转速动态响应曲线变陡, 上升时间变长, 这是由于上升时间受电机机械特性、燃料电池堆的性能等条件所限。通过对控制参数的调节,

空气流量控制系统无超调, 稳态误差很小, 满足车用 PEMFC 的要求。

由图 4.9 可知, 当空压机的转速控制采用 PID 控制策略时, BLDCM 转速响应曲线在不同给定值下的上升时间分别为 2s、3s、4s。当空压机转速控制采用 Fuzzy-PID 复合控制策略时, BLDCM 转速响应曲线在与 PID 控制策略相应的给定值下, 其上升时间分别为 1s、1.5s、2s, 空压机转速响应时间减少了一半。可见, 采用 Fuzzy-PID 复合控制策略后, 控制系统的动态性能得到了明显的改善。

用 Elman 动态回归神经网络建立了根据燃料电池输出功率的变化预测空气流量给定值的预测模型, 它和空气流量控制系统的控制模型一起构成空气流量系统的控制模型。在此模型基础上, 分析 Fuzzy-PID 复合控制策略对 BLDCM 转速的调节作用。通过与传统的 PID 控制策略的仿真结果相比较可知, 采用 Fuzzy-PID 复合控制策略的空气流量控制系统, 提高了控制系统的动态性能, 改善了系统的动态响应过程, 对降低燃料电池系统的寄生功耗、提高电池的发电效率、改善燃料电池的输出性能具有重要作用, 完全满足车用 PEMFC 的要求。


由空气流量 Fuzzy-PID 复合控制策略的研究可知, 控制对象的机理模型建立在理论分析的基础上, 不依赖于实际的测试数据, 因此, 对基于机理模型控制策略的研究, 具有一定的普适性。虽然它针对性较弱, 但由于 PEMFC 的特殊性, 一旦操作失误, 不仅会损坏质子交换膜, 带来无法挽回的损失; 而且, 有可能引起爆炸, 影响参加实验者的人身安全。因此, 对 PEMFC 进行理论分析, 预先确定控制系统适用的控制策略, 明确控制参数的调整范围, 减小实际调试时参数大范围的波动, 避免危险的发生是非常必要的。至于本节研究的电动汽车起步加速阶段空气供应系统的控制, 在确定控制参数工作范围的基础上, 采用基于神经网络辨识模型的神经 PID 控制, 再进一步优化控制系统结构, 使其跟踪控制效果更好。

4.5.3 空气流量神经 PID 控制


在车用 PEMFC 空气流量的神经 PID 控制回路中, 空气流量给定值采用 Elman 神经网络预测模型的动态给定值, 被控对象采用空气流量的神经网络辨识模型, 通过对 PID 控制参数的自动调整, 控制空气流量快速跟随负荷的变化。当车用 PEMFC 负载功率的变化范围分别为额定功率的 20%、40%、60%、80%、100% 时, 空气流量的神经 PID 控制策略, 通过神经网络自动调整 PID 的比例系数 k_p 、积分常数 k_i 和微分常数 k_d , 使空气流量的输出响应实时跟踪系统给定值的变化。

1. 基于 BP 神经网络整定的 PID 控制

基于 BP 神经网络整定的 PID 控制, 自动调整控制参数, 使空气流量的输出响应实时跟踪系统给定值的变化。当车用 PEMFC 的输出负载变化范围分别为额定功率的 20%、40%、60%、80%、100% 时, 基于 BP 神经网络整定的 PID 控制实时调整比例系数 k_p 、积分常数 k_i 和微分常数 k_d , 使空气流量控制回路的输出实时跟踪系统给定值的变化。基于 BP 神经网络的空气流量响应及控制曲线如图 4.10 所示。



(a) 响应曲线



(b) 控制参数调整曲线

图 4.10 基于 BP 神经网络的空气流量响应及控制曲线

在图 4.10(a)中,实线表示空气流量的给定值,虚线表示空气流量控制回路输出响应曲线。图 4.10(b)是基于 BP 神经网络整定的 PID 控制参数,比例系数 k_p 、积分常数 k_i 和微分常数 k_d 的调整曲线。


由图 4.10(a)可知,空气流量控制输出响应曲线与系统的给定值几乎完全重合,达到了非常好的跟踪控制效果。

2. 基于 RBF 神经网络整定的 PID 控制


基于 RBF 神经网络整定的 PID 控制自动调整控制参数,使空气流量的输出响应实时跟踪系统给定值的变化。当车用 PEMFC 的输出负载变化范围分别为额定功率的 20%、40%、60%、80%、100% 时,基于 RBF 神经网络整定的 PID 控制实时调整比例系数 k_p 、积分常数 k_i 和微分常数 k_d ,使空气流量控制回路的输出实时跟踪系统给定值的变化。基于 RBF 神经网络的空气流量响应及控制曲线如图 4.11 所示。

在图 4.11(a)中,虚线表示空气流量的给定值,实线表示空气流量控制回路输出响应曲线。图 4.11(b)是基于 RBF 神经网络整定的 PID 控制参数,比例系数 k_p 、积分常数 k_i 和微分常数 k_d 的调整曲线。

可见, RBF 神经网络通过雅克比信息实时调整 PID 控制参数, 控制参数的调整范围很小, 相应的空气流量跟踪给定值变化的控制效果较 BP 神经网络差。因此, 在实际的空气流量控制回路中, 选择简单实用的 BP 神经网络来整定 PID 控制参数。



(a) 响应曲线



(b) 控制参数调整曲线

图 4.11 基于 RBF 神经网络的空气流量响应及控制曲线

4.5.4 空气流量不同控制策略比较与分析

本节根据空气流量的不同建模方式，分别研究了两种控制策略，即基于机理模型的 Fuzzy-PID 控制策略和基于神经网络辨识模型的神经 PID 控制策略。由于这两种控制策略分别对应于不同的模型，因此各有利弊。

基于空气流量机理模型的 Fuzzy-PID 复合控制策略由于采用的机理模型具有通用性，因此适用范围比较广泛，几乎对所有由无刷直流电机驱动的空压机的转速控制，都可采用此 Fuzzy-PID 复合控制策略的分析方式。但是，由于实际系统模型的复杂性，在本节研究的燃料电池对象上，其控制精度和控制速度可能要略逊色一些。而基于空气流量实验数据建模的神经 PID 控制，针对本节研究的采集实验数据样本的燃料电池对象，其在控制精度和控制速度上要略高一筹。但是，由于实验数据样本的局限性，如果将此神经 PID 控制策略移植到其他不同结构的燃料电池对象中，神经网络的自学习过程将会延长，甚至完全不适用，换句话说，其通用性较差。

可见，两种控制策略各有特点，在实际使用时，对一个新燃料电池对象，可通过 Fuzzy-PID 复合控制策略控制，以收集足够多的数据样本信息，然后再优化控制结构，采用神经 PID 控制策略以适应不断变化的负载的需求。

4.6 空气压力控制策略研究

空气压力对燃料电池的性能有很大影响。提高反应气体压力，PEMFC 的性能和效率均会随之提高。PEMFC 在较高压力下工作时，可以增大燃料电池系统的能量密度，减小系统尺寸，提高电池堆效率和改善水平衡，有利于燃料电池性能的改善。但是受电堆密

封要求、材料的强度及反应安全性所限，从系统优化角度出发，燃料电池的工作压力又不宜过大，且空气压缩机作为提供高压氧气的来源也要消耗功率。

4.6.1 控制系统结构

空气压力控制回路主要由空气压力控制器、空气供给管腔、空气返回管腔、PEMFC、空气压力检测装置和空气压力给定装置等组成。由于空气压力与空气流量直接相关，它的实时调节应与空气流量的实时变化相对应，而且 PEMFC 的反应空气工作压力除了与空气流量直接相关外，还受到电池堆输出功率的影响、电池性能的制约，以及空气温度和排风阀开度等参数的影响，因此，空气压力控制回路的给定值是动态的、非线性的。空气压力控制回路的给定值由 Elman 神经网络根据燃料电池堆输出功率、电池堆温度及空气流量等参数的变化，预测燃料电池的空气工作压力，使其快速响应负荷的变化，提高空气压力控制回路的动态响应能力。同时，为提高控制的实时性，空气压力控制回路的控制模型采用基于空气压力—排风量的参数辨识模型。空气压力控制回路被控变量为电池堆入口的空气压力，控制变量为排风量。空气压力控制结构方框图如图 4.12 所示。

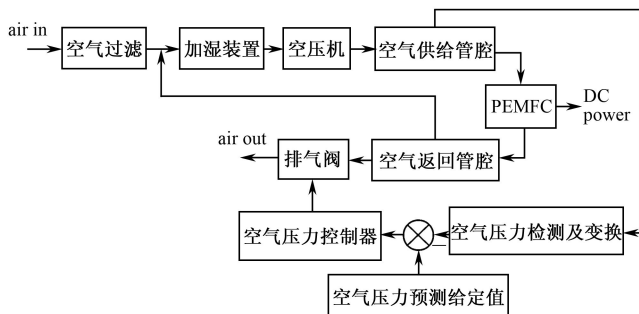


图 4.12 空气压力控制结构方框图

空气压力的神经 PID 控制策略, 通过控制燃料电池堆空气返回管腔的排风阀开度, 控制空气压力的变化。PEMFC 的燃料是氢气和环境大气中的氧气。氢气由高压储气瓶经减压后供给, 因此燃料电池的功率密度主要由空气中的氧分压决定。相关文献^[59~64]从不同侧面论述了提高反应气体的工作压力有利于改善燃料电池的性能和提高燃料电池堆的工作效率。适当提高空气压力有利于燃料电池性能的改善, 但受电池堆密封要求、材料强度及反应安全性所限, 从系统优化角度出发, 燃料电池的工作压力又不宜过大。由于氢气的工作参数存在最佳值^[59], 因此, 先将氢气的工作参数调整到最佳状态, 然后再根据电池堆的输出功率、空气流量、空气温度等参数的变化调节空气的工作压力, 使系统运行在最佳状态。

基于 Elman 动态神经网络的空气压力给定值的预测模型和基于空气压力控制回路的控制模型, 建立了空气压力控制回路。分析了基于参数辨识模型和基于神经网络辨识模型的空气压力采用神经 PID 控制策略时, 控制系统在模拟电动汽车起步加速阶段时的响应过程。仿真结果表明, 空气压力采用神经 PID 控制策略完全可以跟踪空气流量和燃料电池堆输出功率的变化, 满足 PEMFC 输出功率的需求。空气压力的神经 PID 控制策略主要研究两种控制方式, 即基于 BP 神经网络整定的 PID 控制方式和基于 RBF 神经网络整定的 PID 控制方式。

在空气压力控制回路中, 神经 PID 控制器要取得较好的控制效果, 就必须调整好比例、积分和微分 3 种控制作用, 形成控制量之间既相互配合又相互制约的关系^[112~116]。空气压力神经 PID 控制系统方框图如图 4.13 所示。

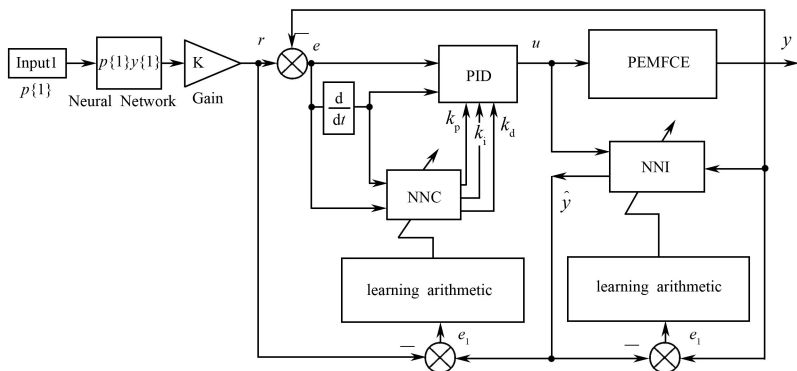


图 4.13 空气压力神经 PID 控制系统方框图

神经 PID 控制系统中，采用了两个神经网络，一个是神经网络辨识器 NNI，另一个是神经网络控制器 NNC，通过实时调整 NNC 的权系数，使系统的输出具有自适应性。本节根据 NNC 采用的控制算法的不同，研究空气压力基于 BP 神经网络整定的 PID 控制和基于 RBF 神经网络整定的 PID 控制。

4.6.2 基于参数辨识模型的神经 PID 控制

空气压力控制回路采用神经 PID 控制策略。空气压力的神经 PID 控制策略主要研究两种控制方式，即基于 BP 神经网络整定的 PID 控制方式和基于 RBF 神经网络整定的 PID 控制方式。

1. 基于 BP 神经网络整定的 PID 控制

空气压力控制回路采用基于 BP 神经网络整定的 PID 控制器，它利用神经网络具有任意非线性表达能力，通过对系统性能的学习来实现具有最佳组合的 PID 控制，它根据系统的运行状态，调节 PID 控制器的参数 k_p 、 k_i 、 k_d 。

基于 BP 网络的 PID 控制器主要由两部分构成，一是经典的 PID 控制器，直接对被控对象进行闭环控制，并且 3 个参数 k_p 、 k_i 、 k_d 为在线调整方式；二是神经网络，根据系统的运行状态，调节 PID 控制器的参数，以期达到某种性能指标的最优化。输出层神经元的输出状态对应于 PID 控制器的 3 个可调参数 k_p 、 k_i 、 k_d ，通过神经网络的自学习和加权系数的调整，使系统的稳定状态对应于某种最优控制律下的 PID 控制器参数。BP 神经网络结构如图 4.14 所示^[114]。




图 4.14 BP 神经网络结构

可见，BP 神经网络有 M 个输入节点，对应空气压力控制回路的运行状态量，如系统不同时刻的输入量和输出量等，为防止部分神经元出现饱和，对其进行归一化处理。输出节点分别对应 PID 控制器的 3 个可调参数 k_p 、 k_i 、 k_d ， Q 为隐含层节点的个数。

空气压力控制回路的 BP 神经网络选用 4-3-3 三层结构，即 BP 网络的输入层为空气压力给定值 $r(k)$ 、空气压力实测值 $y(k)$ 、空气压力偏差值 $e(k) = r(k) - y(k)$ 及阈值 M 。输出值分别是 PID 控制器的 3 个可调参数 k_p 、 k_i 、 k_d 。基于 BP 网络整定的 PID 控制器结构图如图 4.15 所示。

BP 神经网络的输入为：

$$\begin{cases} O_j^{(1)} = x_{k-j} & (j=0, 1, 2) \\ O_3^{(1)} \equiv 1 \end{cases} \quad (4.20)$$

网络的隐含层输入、输出为：

$$\begin{cases} \text{net}_i^{(2)}(k) = \sum_{j=0}^3 w_{ij}^{(2)} O_j^{(1)}(k) \\ O_i^{(2)}(k) = f[\text{net}_i^{(2)}(k)] & (i=0, 1, 2, 3) \\ O_4^{(2)}(k) \equiv 1 \end{cases} \quad (4.21)$$

式中， $w_{ij}^{(2)}$ 为隐含层加权系数， $w_3^{(2)} = \theta_i$ 为阈值， $f(\cdot) = \tanh(x)$ 为活化函数，上角标 (1)、(2)、(3) 分别表示输入层、隐含层、输出层。




图 4.15 基于 BP 网络整定的 PID 控制器结构图

BP 网络的输出层输入、输出为：

$$\begin{cases} \text{net}_l^{(3)}(k) = \sum_{i=0}^4 w_{li}^{(3)} O_i^{(2)}(k) \\ O_l^{(3)}(k) = g[\text{net}_l^{(3)}(k)] \\ O_0^{(3)}(k) = k_p \\ O_1^{(3)}(k) = k_i \\ O_2^{(3)}(k) = k_d \end{cases} \quad (l=0, 1, 2) \quad (4.22)$$

式中, $w_{li}^{(3)}$ 为输出层加权系数, $w_{lj}^{(3)} = \theta_j$ 为阈值, $g(\cdot) = (1/2)[1 + \tanh(x)]$ 为活化函数, 上角标(1)、(2)、(3)分别表示输入层、隐含层、输出层。

取性能指标函数为:


$$J_1 = \frac{1}{2} [r(k+1) - y(k+1)]^2 = \frac{1}{2} \alpha(k+1)^2 \quad (4.23)$$

经典增量式数字 PID 控制算法为:


$$u(k) = u(k-1) + k_p(\alpha(k) - \alpha(k-1)) + k_i\alpha(k) + k_d(\alpha(k) - 2\alpha(k-1) + \alpha(k-2)) \quad (4.24)$$

根据式(4.22)~式(4.24)前向计算各层神经元的输入和输出, 输出层的输出即为 PID 控制器的 3 个可调参数 k_p 、 k_i 、 k_d 。然后, 根据式(4.24)计算 PID 控制器的控制输出 $u(k)$, 参与控制和计算。在学习过程结束之前, 若空气压力控制回路的输出值 $y(k)$ 与给定值 $r(k)$ 之间存在误差, 则转入反向传播, 将误差沿原来连接的通路回送, 进行神经网络学习, 在线调整加权系数 $w_{ij}^1(k)$ 和 $w_{li}^2(k)$, 直到性能指标函数满足要求为止, 从而实现了 PID 控制参数的自适应调整^[121]。

当预测空气压力的 Elman 神经网络的输入值 $p\{1\}$ 取不同值时, 其输出值 $y\{1\}$ 也不同, 因此空气压力控制回路的给定值发生变化, 基于 BP 神经网络整定的 PID 控制器, 通过调节 PID 控制器的 3 个可调参数 k_p 、 k_i 、 k_d , 控制空气压力的输出值随给定值变化而变化。空气压力的单位阶跃响应曲线及基于 BP 神经网络整定的 PID 控制参数 k_p 、 k_i 、 k_d 的调整曲线分别如图 4.16(a)、图 4.16(b) 所示。




(a) 单位阶跃响应曲线




(b) PID控制参数调整曲线

图 4.16 空气压力单位阶跃响应及 BP 网络控制曲线

当预测空气压力的 Elman 神经网络的输出值为 0.37 时, 空气压力阶跃响应曲线及基于 BP 神经网络整定的 PID 控制参数 k_p 、 k_i 、 k_d 的调整曲线分别如图 4.17(a)、图 4.17(b) 所示。



(a) 幅值为0.37的阶跃响应曲线



(b) PID控制参数调整曲线

图 4.17 空气压力输出值为 0.37 时的阶跃响应及 BP 网络控制曲线

通过比较图 4.16 和图 4.17 可知, 空气压力控制回路采用基于 BP 神经网络整定的 PID 控制策略时, 能自动调整 PID 控制器的控制参数 k_p 、 k_i 、 k_d , 使空气压力快速响应由 Elman 神经网络预测的空气压力给定值的变化。基于 BP 神经网络整定的 PID 控制器由于具有控制参数自调整功能, 因此可以适应燃料电池负载的快速变化及其引起的空气流量和燃料电池堆温度的改变。换句话说, 基于 BP 神经网络整定的 PID 控制器使空气压力控制回路具有自适应能力。

2. 基于 RBF 神经网络整定的 PID 控制

基于 RBF 神经网络整定的 PID 控制器仍采用增量式控制算法, 神经网络整定指标见式 (4.23), 而控制参数 k_p 、 k_i 、 k_d 的调整则采用梯度下降法。

$$\Delta k_p = -\eta \frac{\partial E}{\partial k_p} = -\eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_p} = \eta \alpha(k) \frac{\partial y}{\partial u} (\alpha(k) - \alpha(k-1)) \quad (4.25)$$

$$\Delta k_i = -\eta \frac{\partial E}{\partial k_i} = -\eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_i} = \eta \alpha(k) \frac{\partial y}{\partial u} \alpha(k) \quad (4.26)$$

$$\Delta k_d = -\eta \frac{\partial E}{\partial k_d} = -\eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_d} = \eta \alpha(k) \frac{\partial y}{\partial u} (\alpha(k) - 2\alpha(k-1) + \alpha(k-2)) \quad (4.27)$$

式中, $\frac{\partial y}{\partial u}$ 为被控对象的雅克比信息, 可通过神经网络的辨识得到。

基于 RBF 神经网络整定的 PID 控制图如图 4.18 所示。






图 4.18 基于 RBF 神经网络整定的 PID 控制方框图

当预测空气压力的 Elman 神经网络的输入值 $p\{1\}$ 取不同值时，同样，其输出值 $y\{1\}$ 不同，空气压力控制回路的给定值发生变化，基于 RBF 神经网络整定的 PID 控制器，通过被控对象的 Jacobian 信息调节 PID 控制器的 3 个可调参数 k_p 、 k_i 、 k_d ，使空气压力的输出值随给定值变化。空气压力的单位阶跃响应曲线及基于 RBF 神经网络整定的 PID 控制参数 k_p 、 k_i 、 k_d 的调整曲线分别如图 4.19(a)、图 4.19(b) 所示。




(a) 单位阶跃响应曲线




(b) PID控制参数调整曲线

图 4.19 空气压力单位阶跃响应及 RBF 网络控制曲线

当预测空气压力的 Elman 神经网络的输出值为 0.37 时，空气压力阶跃响应曲线及基于 RBF 神经网络整定的 PID 控制参数 k_p 、 k_i 、 k_d 的调整曲线分别如图 4.20(a)、图 4.20(b) 所示。



(a) 幅值为0.37的阶跃响应曲线



(b) PID控制参数调整曲线

图 4.20 空气压力输出值为 0.37 时的阶跃响应及 RBF 网络控制曲线

通过比较图 4.19 和图 4.20 可知，空气压力控制回路采用基于 RBF 神经网络整定的 PID 控制策略时，能自动调整 PID 控制器的控制参数 k_p 、 k_i 、 k_d ，使空气压力快速响应由 Elman 神经网络预测的空气压力给定值的变化。基于 RBF 神经网络整定的 PID 控制器由于具有控制参数自调整功能，因此可以适应燃料电池负载的快速变化及其引起的空气流量和燃料电池堆温度的改变。换句话说，基于 RBF 神经网络整定的 PID 控制器使空气压力控制回路具有自适应能力。

空气压力控制回路分别采用两种神经 PID 控制策略，即基于 BP 神经网络整定的 PID 控制策略和基于 RBF 神经网络整定的 PID 控制策略，由仿真结果的比较可知，空气压力采用神经 PID 控制，能够自动调整 PID 的控制参数 k_p 、 k_i 、 k_d ，使空气压力快速响应燃料电池堆输出功率、电池堆工作温度和空气流量的变化，使空气压力控制回路具有较强的自适应能力。

而空气压力控制回路采用传统的 PID 控制策略时, 当空气压力给定值改变时, 控制参数需要重新整定。在实际的车用 PEMFC 空气压力控制回路中, 由于操作环境的不断改变, 需要不断地调整 PID 的控制参数, 这几乎不可能实现, 因此, 传统的 PID 控制策略不适用于实际的空气压力控制回路。

空气压力控制回路的仿真曲线也表明, 由神经网络组成的空气压力控制回路响应时间短, 响应误差小, 具有良好的动、静态性能指标。


4.6.3 基于神经网络辨识模型的神经 PID 控制

将经过训练的 Elman 神经网络预测模型和基于 Elman 神经网络辨识的 PEMFC 空气压力辨识模型, 加入空气压力控制回路的 Simulink 模型中, 分别作为空气压力控制回路的给定值预测模型和被控对象模型。空气压力控制回路采用神经 PID 控制, 当神经网络预测给定值的输入 $p\{1\}$ 取值不同时, 神经 PID 控制器自动调整 PID 的控制参数。


1. 基于 BP 神经网络整定的 PID 控制

基于 BP 神经网络整定的 PID 控制自动调整控制参数, 使空气压力的输出响应实时跟踪系统给定值的变化。当车用 PEMFC 的输出负载变化范围分别是 20%、40%、60%、80%、100% 时, 基于 BP 神经网络整定的 PID 控制实时调整比例系数 k_p 、积分常数 k_i 和微分常数 k_d , 使空气压力控制回路的输出实时跟踪系统给定值的变化。基于 BP 神经网络的空气压力响应及控制曲线如图 4.21 所示。

在图 4.21(a) 中, 虚线表示空气压力的给定值, 实线表示空气压力控制回路输出响应曲线。图 4.21(b) 是基于 BP 神经网络整定的 PID 控制参数, 比例系数 k_p 、积分常数 k_i 和微分常数 k_d 的调整曲线。



(a) 响应曲线



(b) 控制参数调整曲线


图 4.21 基于 BP 神经网络的空气压力响应及控制曲线

可见，通过 BP 神经网络实时调整 PID 控制参数，可使空气压


力快速跟随给定值的变化。在图 4.21 中,当车用 PEMFC 的输出负载由 20% 突然变化至 80% 时, PID 控制参数,即比例系数 k_p 、积分常数 k_i 和微分常数 k_d 均有较大幅度的变化,响应误差较大;在平稳的过渡期,即车用 PEMFC 的输出负载由 60% 增至 80%,再到 100% 时, PID 控制参数变化较平稳,具有较好的跟踪控制效果。

2. 基于 RBF 神经网络整定的 PID 控制

基于 RBF 神经网络整定的 PID 控制自动调整控制参数,使空气压力的输出响应实时跟踪系统给定值的变化。当车用 PEMFC 的输出负载变化范围分别是 20%、40%、60%、80%、100% 时,基于 RBF 神经网络整定的 PID 控制实时调整比例系数 k_p 、积分常数 k_i 和微分常数 k_d ,使空气压力控制回路的输出实时跟踪系统给定值的变化。基于 RBF 神经网络的空气压力响应及控制曲线如图 4.22 所示。在图 4.22(a) 中,实线表示空气压力的给定值,虚线表示空气压力控制回路输出响应曲线。图 4.22(b) 是基于 RBF 神经网络整定的 PID 控制参数,比例系数 k_p 、积分常数 k_i 和微分常数 k_d 的调整曲线。



(a) 响应曲线



(b) 控制参数调整曲线

图 4.22 基于 RBF 神经网络的空气压力响应及控制曲线

可见，通过 RBF 神经网络实时调整 PID 控制参数，可使空气压力快速跟随给定值的变化。在图 4.22 中，当车用 PEMFC 的输出负载由 20% 突然变化至 80% 时，PID 控制参数，即比例系数 k_p 、积分常数 k_i 和微分常数 k_d 均有较大幅度的变化；当车用 PEMFC 的输出负载由 60% 增至 80%，再到 100% 时，输出响应比较平稳，没有超调现象发生。

RBF 神经网络通过雅克比信息实时调整 PID 控制参数，控制参数的调整范围较 BP 神经网络小，相应的空气压力跟踪给定值的变化比较平稳。因此，在实际的空气压力控制回路中，选择 RBF 神经网络来整定 PID 控制参数，控制效果相对而言会好一些。虽然在空气压力全量程范围内，系统输出响应误差较大，但是，输出响应全过程无超调，彻底避免了振荡现象的发生，具有较好的跟踪控制效果。

4.6.4 空气压力不同模型控制策略比较与分析

本节根据空气压力的不同建模方式,分别研究了两种神经PID控制策略,即基于参数辨识模型的神经PID控制策略和基于神经网络辨识模型的神经PID控制策略。由于空气压力与空气流量是时变的、非线性、强耦合的一对变量,因此,燃料电池空气流量的改变必然影响空气压力。本节根据实验数据建立了燃料电池的空气压力随空气流量改变的实验模型。由于神经PID控制策略的控制模型均由实验建立,因此,仅适用于本节的燃料电池空气供给控制系统。

基于参数辨识模型和基于神经网络辨识模型的神经PID控制策略,相对而言,基于神经网络辨识模型的神经PID控制策略要稍好一些。因为采用参数辨识建模时,由于系统阶次所限,或多或少总有一些舍入误差,况且参数模型一旦确定,其适应性就较差。因此,实际控制时,优先选用基于神经网络辨识模型的神经PID控制策略。

4.6.5 小结

本节用Elman神经网络预测空气参数随燃料电池堆输出功率和电池堆工作温度等参数变化的趋势,分别将其作为空气流量控制回路和空气压力控制回路的空气参数给定值。并且根据空气流量的不同建模方式,分别研究了空气流量基于机理模型的Fuzzy-PID控制策略和基于神经网络辨识模型的神经PID控制策略,并分析了空气流量控制回路采用两种不同控制策略时的特点。然后,研究了空气压力基于参数辨识模型和基于神经网络辨识模型的神经PID控制策略,并分析了空气压力控制回路采用不同控制策略时的控制响应。通过对空气流量控制回路和空气压力控制

回路控制策略的研究,用 MATLAB 对基于不同模型的不同控制策略进行了仿真。仿真结果表明,空气流量控制回路对燃料电池输出功率的变化具有较快的响应速度,空气压力控制回路对燃料电池输出功率和空气流量的变化具有较强的自适应能力。

基于驱动空压机的高速无刷直流电动机的机理模型,设计了空气流量的 Fuzzy-PID 复合控制策略,并确定了 P、I、D 参数的调整范围;基于排风阀 空气压力参数辨识模型,设计了空气压力的神经 PID 控制策略;这两种控制策略具有一定的普适性,但针对性较弱,影响控制精度及实时性;基于电动汽车起步加速阶段测试数据,建立的空气流量、空气压力神经网络辨识模型,针对性较强,采用神经 PID 控制策略时,空气流量、空气压力具有很好的跟踪控制功能;通过仿真,分析了空气流量、空气压力采用不同控制策略时的动态响应过程。仿真结果证明,空气流量、空气压力采用 Fuzzy-PID 复合控制策略、神经 PID 控制策略等智能控制策略时,相对于传统的 PID 控制策略具有较大的优越性;同时还说明了神经 PID 控制通过对控制参数的自调整功能,可快速响应车用 PEMFC 输出功率的变化。

用线性近似法建立的空气流量控制回路和空气压力控制回路的控制模型,为空气供应系统控制策略的普适性研究提供了依据。但是,由于空气供应系统的本质非线性特点,将空气供应系统近似为线性系统的研究,其控制精度及控制的实时性受到一定的影响。为了对本节研究的电动汽车起步加速阶段的工况进行很好的模拟,利用神经网络能逼近任意非线性系统的特点,根据电动汽车起步加速阶段所测得的实验数据,建立的空气流量控制回路和空气压力控制回路的控制模型,可以较好地拟合实际的空气供应系统模型,因此,用神经网络辨识模型代替实际模型,以进行电动汽车起步加速阶段的神经 PID 控制策略的研究。仿真结果表明,空气流量控制回路和空气压力控制回路具有较快的响应速度和较强的自适应能力,具有较好的控制性能,因此,可以满足车用 PEMFC

对电动汽车空气供给的需求。

4.7 基于自适应神经网络的空气供应系统控制

上一节用PID控制方法对燃料电池系统空气供应系统进行了控制，PID控制实现简单，但控制精度不高，尤其是没有考虑到控制变量对系统输出电压的影响，从而难以评价PID控制对系统输出功率的影响。本节将状态空间方程和神经网络结合起来，建立空气供应系统的混合模型，基于此模型进行神经自适应控制的设计。

4.7.1 状态空间模型

根据第2章建立的数学模型及第3章的模拟仿真软件，对空气供应系统进行线性化，得到状态空间方程。该状态空间方程的控制变量为进堆空气流量，即 $u = W_{cp}$ ，状态变量为电堆供应管腔空气质量 m_{sm} 、阴极氧气质量 m_{O_2} 、阴极氮气质量 m_{N_2} 、阳极氢气质量 m_{H_2} 、阴极回流管腔质量 m_{tm} ，即 $x = [m_{sm}, m_{O_2}, m_{N_2}, m_{tm}]$ ，输出为 $y = [m_{O_2}, m_{N_2}]$ ，状态空间方程的表达式为：

$$\dot{x} = Ax + Bu$$

$$y = Cx + Du$$

系数 A , B , C , D 分别如下：

$$A = \begin{bmatrix} -21.709 & -43.449 & -48.547 & 0 \\ -3.34 & -4.097 & -270.67 & 0 \\ -20.157 & -4.1 & -7.47 & 0 \\ 90.41 & 103.29 & 160.6 & -42.748 \end{bmatrix}$$

$$B = [0.218 \quad 0.716 \quad 0.066 \quad 1]^T$$

$$C = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

$$D = 0$$

4.7.2 神经网络模型

在燃料电池系统中预测系统输出电压 v_{st} 非常重要^[117]，一些学者已经提出了一些机理模型或经验模型来计算 v_{st} ，但这些模型大多数非线性很强且有很多参数需要确定，难以用到系统的实时控制中。本节用人工神经网络建立系统输出电压模型，应用到空气供应系统的控制中。神经网络包括输入层、隐含层和输出层。输入是氧气的质量 m_{O_2} 、氢气的质量 m_{H_2} 、氮气的质量 m_{N_2} 及系统给定电流 I_{st} ，输出是系统输出电压 v_{st} ， ω^1 是输入层和隐含层间的权值， ω^2 是隐含层和输出层之间的权值。

神经网络各层的输出如下。

隐含层的输出为：

$$I_j = f\left(\sum_{i=1}^4 \omega_{ij}^1 x_i - \theta_j\right) \quad j=1, 2, \dots, n \quad (4.28)$$

式中， ω_{ij}^1 是连接输入 x_i 和隐含层中第 j 个神经元的权值； θ_j 是隐含层中第 j 个神经元的阈值； $f(\bullet)$ 是作用函数， $f(x) = 1/(1 + \exp(-x))$ 。

输出为：

$$v_{st} = \sum_{j=1}^n \omega_j^2 I_j \quad (4.29)$$

式中， ω_j^2 是连接输出 v_{st} 和隐含层神经元 j 的权重。

权重的学习是为了使输出误差的绝对值的平方最小，输出误

差通过比较神经网络的计算值和期望输出值得出，即：

$$J(\omega) = \frac{1}{2} \sum_{i=1}^M [y_{it} - y_{in}(\omega)]^2 \quad (4.30)$$

式中， y_{it} 是期望输出值， y_{in} 是从神经网络中计算得到的输出值， M 是训练数据的数目， ω 是权值。许多优化方法已经成功应用于求解此优化问题，这里采用改进了的方向反馈算法。训练数据集来源于实验结果。

4.7.3 自适应神经网络控制器

建立起结合状态空间与神经网络的混合模型之后，采用自适应神经网络控制的方法对燃料电池系统空气供应系统进行控制，自适应神经网络控制的示意图如图 4.23 所示。




图 4.23 自适应神经网络控制示意图

在空气供应系统中，氧气过量系数 λ_{O_2} 是一个重要的参数，它的定义是提供给燃料电池电堆的氧气流量和电堆消耗的氧气流量之间的比值，即：

$$\lambda_{O_2} = W_{O_2, in} / W_{O_2, rct}(I_{st}) \quad (4.31)$$

电堆消耗的氧气流量 $W_{O_2, rct}(I_{st})$ 和电堆的电流密切相关，可用下式算出：

$$W_{O_2, \text{rect}}(I_{\text{st}}) = \frac{nI_{\text{st}}}{4F} \quad (4.32)$$

氧气过量系数 λ_{O_2} 的大小和电堆的净输出功率密切相关, 当氧气过量系数 λ_{O_2} 较小时, 氧气供应不足, 燃料电池会产生“挨饿”现象, 使电堆输出电压降低; 当氧气过量系数 λ_{O_2} 较大时, 氧气供应充足, 电堆输出电流、电压和燃料电池伏安特性相符合, 但如果 λ_{O_2} 太大, 风机需要消耗电能, 就会使电堆净输出功率降低。一般来说, λ_{O_2} 取 2 较为合适, 即 $\lambda_{O_2}^{\text{ref}} = 2$ 。

影响 λ_{O_2} 的大小的变量是控制输入 $u = v_{\text{cm}}$ 和电堆电流 I_{st} , 通过线性化, 可得:

$$\lambda_{O_2} = N_1 x + N_2 u \quad (4.33)$$

空气供应系统控制目标是维持氧气过量系数为 2, 同时使电堆的输出总功率最大, 即目标函数为:

$$J = -Q_1(I_{\text{st}} v_{\text{st}})^2 + Q_2(\lambda_{O_2} - \lambda_{O_2}^{\text{ref}})^2 \quad (4.34)$$

式中, Q_1 , Q_2 是权重, 控制的目标即是目标函数 J 最小。

令 $\frac{\partial J}{\partial u} = 0$, 即:

$$\frac{\partial J}{\partial u} = -2Q_1(I_{\text{st}} v_{\text{st}})I_{\text{st}} \frac{\partial v_{\text{st}}}{\partial u} + 2Q_2(N_1 x + N_2 u - \lambda_{O_2}^{\text{ref}})(N_1 \frac{\partial x}{\partial u} + N_2) \quad (4.35)$$

所以控制变量可由下式得出:

$$u = \frac{[Q_2(v_{\text{st}} - y) - Q_1(I_{\text{st}} v_{\text{st}})] \frac{\partial v_{\text{st}}}{\partial u}}{Q_2 N_2 \left(N_2 + \frac{\partial x}{\partial u} \right)} + \frac{\lambda_{O_2}^{\text{ref}} - N_1 x}{N_2} \quad (4.36)$$

式中, v_{st} 是按照神经网络计算公式计算得出的。

则 $\frac{\partial v_{\text{st}}}{\partial u}$ 可写成

$$\frac{\partial V_{st}}{\partial u} = \frac{\partial V_{st}}{\partial I} \frac{\partial I}{\partial x} \frac{\partial x}{\partial u} = \sum_{j=1}^n \omega_j^2 \sum_{i=1}^3 \omega_i^1 \frac{\partial x}{\partial u} \quad (4.37)$$

式中, $\frac{\partial x}{\partial u}$ 可由下式计算:

$$\frac{\partial x}{\partial u} = \frac{\partial}{\partial u} \left[\int_0^t \exp(A(t-\tau)) Bu(\tau) d\tau \right] \quad (4.38)$$

为了简化, 有:

$$\frac{\partial x}{\partial u} = \exp(At)B$$

将式 (4.37) 和式 (4.38) 代入式 (4.36), 则有:

$$u = \psi_1(V_{st} - y) + \psi_2 V_{st} + \psi_3 \quad (4.39)$$

其中,

$$\psi_1 = Q_2 \mathcal{G}_1 / \mathcal{G}_2$$

$$\psi_2 = -Q_1 I_{st} \mathcal{G}_1 / \mathcal{G}_2$$


$$\mathcal{G}_1 = \sum_{j=1}^n \omega_j^2 \sum_{i=1}^3 \omega_i^1 \exp(At)B$$

$$\mathcal{G}_2 = Q_3 N_2 (N_2 + \exp(At)B)$$


4.7.4 仿真结果

将以上建立的状态空间模型和已经训练好的神经网络结合起来, 得到系统的混合模型。根据此模型, 用上节提出的自适应神经网络控制器对燃料电池空气供应系统进行控制, 仿真结果如图 4.24 所示。燃料电池系统的功率随电堆电流的变化而变化, 电堆电流的变化如图 4.24 (a) 所示, 氧气过量系数的变化如图 4.24 (b) 所示, 电堆输出功率如图 4.24 (c) 所示。从图中可以看出, 自适应神经网络控制的响应速度很快, 当电堆电流上下波动时, 氧气过量系数迅速变化, 但在 0.2 秒内迅速回到参考值 $\lambda_{O_2}^{\text{ref}}$ 。而且功率的变化能够迅速跟上电流变化, 即能够对负载要求实时响应。所以本章


设计的自适应神经网络控制器能够提供足够的氧气，满足燃料电池的要求，同时也证明该控制器是可行的。



(a) 电堆电流



(b) 氧气过量系数



(c) 电堆输出功率

图 4.24 自适应神经网络控制仿真结果

第 5 章 质子交换膜燃料电池 系统水管理

5.1 概 述

在燃料电池系统中，水管理是一个至关重要的问题。电堆中的质子交换膜必须保持适当的湿度，太少的水会导致干膜，增加质子渗透阻力，从而降低电堆输出电压；太多的水会导致“淹膜”，阻碍气体传输，降低气体向催化剂层的传输能力，从而降低电堆输出电压^[118]。不合适的水管理不仅会降低燃料电池系统的性能，而且会缩短燃料电池系统的寿命。因为湿度反复的干湿变化，会导致质子交换膜和催化剂层性能下降，如在干湿频繁交替变化的情况下会使催化剂脱落或质子交换膜破裂。因此燃料电池系统的水管理关系到燃料电池系统的性能及寿命，是一个非常重要的问题。

许多文献讨论过水管理问题，如有一些实验研究用来了解水传输过程和研究影响质子交换膜中水含量的因素等^[39, 119]。Shimpalee 等^[120]研究了包括水的相变和热传输模型的时间相关三维模拟，观测了固定氢气和水流量、变电子负载情况下的水管理情况。为了维持燃料电池电堆中合适的湿度，一些学者建立了相关的水传输数学模型。例如，Chen 等^[12]建立了一维模型来研究质子交换膜中水传输的动态行为；Alessandro 等^[121]建立了基于更高阶的 1&1D 模型的静态映射的面向控制的燃料电池系统模型；Wolfgang 等^[122]则建立了一套测量燃料电池电堆内阻的装置，实验

结果表明质子交换膜的湿度对燃料电池输出电压有重要影响；Gorgun 等^[118, 123]通过测量电堆电压、电流、温度和反应物压力等，计算电堆中质子交换膜的水含量；Hung^[23]则建立了一阶一维水热管理模型用来生成燃料电池电堆的电流—电压曲线，该模型考虑了各种因素的影响，包括沿电堆流道方向的膜中水传输、活化过电势、欧姆过电势、浓差过电势和电流密度等。

虽然很多研究者研究了水管理及水传输机理并根据这些机理建立了三维、二维、一维甚至 0 维模型，但关于如何利用这些模型进行燃料电池电堆湿度控制的研究相对较少。Trung 等^[124]提出了除去电堆中多余液态水的方法，该方法通过控制每一片燃料电池轮流排出尾气，使得在每一时刻只有一片燃料电池排出尾气，从而使该时刻燃料电池内外压力差大，尾气排放充分，流道中多余液态水被排出。这种方法在燃料电池单片数目较少时效果较好，但在燃料电池单片数目较大甚至达到几百片时，有效控制每一片燃料电池轮流排尾气是一个难以实现的问题。Chen 等^[125]建立了膜加湿系统的数学模型，并设计了比例反馈控制策略来调节进入电堆空气的相对湿度。基于 Mamadani 推理系统，Abtahi 等^[126]提出了用于燃料电池电堆水管理的模糊控制器。

5.2 基于回归神经网络优化的模型预测控制

本节利用第 2 章建立的燃料电池模型，用模型预测控制方法来维持燃料电池中合适的湿度。

模型预测控制是一个在工业中广泛使用的处理多变量约束控制问题的有效方法，在燃料电池控制研究中，有些研究者用到了模型预测控制方法，第 1 章中对此已有详细描述。模型预测控制

的主要思想是通过在每一采样时刻在线求解优化控制问题得到一个控制输出,该优化控制问题以使一个二次性能指标最小为优化目标,满足被控对象的动态数学模型及给定的输入和状态约束。一般来说,求解这一优化控制问题的方法是二次规划(QP)方法。但模型预测控制需要在每一采样时刻求解QP问题,而燃料电池水管理的采样时间很短,这就出现了实时的问题。虽然有一些方法可以提高QP的计算速度,如活动集方法,但还是难以满足要求,这也是长期以来模型预测控制方法只应用于石化、化工等采样周期长的过程工业中,而不能应用到采样周期短的“快系统”中的原因,所以将模型预测控制的方法应用到燃料电池控制中是一个挑战,需要解决实时性问题。也有一些方法用来降低预测控制中QP求解的计算速度,最普遍的方法是QP近似求解法,如文献[127]中就通过一个量化条件,提出了模型预测控制下的QP近似解法;还有一种方法是离线的方法,如文献[128]中将QP问题转化为多参数QP(mp-QP)问题,在离线时求出各种可能初始条件下的解,然后应用到在线求解中,这就大大降低了在线计算速度。但这两种方法只能得出QP问题的近似解,会降低预测控制的控制性能,属于牺牲控制性能换取计算速度的方法。

在求解QP问题时还有一种方法,即电路求解方法,后来演化成神经网络的方法,该方法在第1章中有详细描述。本章利用反馈神经网络求解QP问题,提高QP问题的计算速度,解决模型预测控制应用于燃料电池控制中的实时性问题。

随着控制理论的发展,控制的目的不再是满足超调量、调节时间等控制性能指标,还要加上和被控对象相关的经济指标,而且系统要在一定的约束条件下运行,即所谓“优化控制”问题。在优化控制理论中优化方法占据重要地位,优化方法的收敛性及计算速度等对控制的性能及实时性有重要影响,下面对优化方法作一综述。优化控制最常见的是二次规划问题,对此问题通常采

用积极集法或内点法进行求解^[129]。积极集法已经有近 60 年的历史,应用广泛,理论基本成熟,但仍在茁壮成长;而内点法自 20 世纪 80 年代以来成为研究的热点,并被称为约束优化发展的主要推动力。到目前为止,MPC 中常用的求解方法仍然是积极集法,内点法也逐步获得应用^[130~131]。关于提高优化的计算效率问题有几种方法,一类是并发求解方法,也称多重打靶法^[132];另一类是缩小求解规模,降低在线计算量,如次优 MPC^[133]、缩短时域长度^[127]、集结优化^[134]等;还有一类是把在线优化部分或全部转化为离线求解方法,如 Explicit MPC^[128]等。

在优化计算的诸多方法中,有一种方法是用电路来求解,这种方法由 Dennis 在 1959 年提出,后来 Tank 和 Hopfield^[135]提出用模拟电路实现的递归神经网络来求解优化问题,这就是著名的 Hopfield 神经网络, Hopfield 用它求解了旅行商问题。虽然 Hopfield 神经网络有一个缺陷,即神经网络的平衡点可能不是原问题的解,但它的优点在于易用电路实现,可在电路时间常数级内求解大规模复杂的优化问题,比传统的数学规划算法迅速快捷。他们开创性的工作激发其他研究者提出新的神经网络来解决线性规划和非线性规划问题。经过国内外学者的努力,用神经网络求解优化问题发展很快,主要求解了 3 类问题:线性规划问题、非线性规划问题及混合整数规划问题。线性规划相对比较完善。Kennedy 和 Chua^[136]增加了一个有限惩罚参数,将 Hopfield 神经网络扩展,使之能够解非线性规划问题,他们的网络实际上是根据惩罚函数实现了 Kuhn-Tucker 优化条件,当惩罚参数非常大时,惩罚函数难以实现,而且由于惩罚参数的存在,该神经网络难以求得精确优化解。为了改进这个问题,Rodriguez-Vazquez 等^[137]提出了开关电容 (switched-capacitor) 神经网络用于求解一类非线性凸规划问题,该神经网络适用于优化解位于可行区域内的情形,否则神经网络可能没有平衡点。还有一些研究者^[138~140]提出一层或二层主对偶 (primal-dual) 神经网络用于求解线性规划和

非线性规划问题,当目标函数是凸函数时,这些神经网络被证明是全局收敛的。Xia 等^[139]提出了二层神经网络用于求解非线性凸规划问题,在目标函数满足 Lipschitz 连续性条件时,该神经网络能全局收敛到原问题的精确解;为了去掉这个 Lipschitz 连续性条件,Tao 等^[140]提出了另一种二层神经网络,在目标函数满足严格凸条件时,该神经网络被证明能全局收敛到原问题的精确解。后来 Xia 等^[141~143]提出了回归神经网络,该神经网络结构相对简单,实现较容易,可以求解线性约束的非线性凸规划问题。对于混合整数规划,Watta 等^[144]提出用罚函数方法来定义一个梯度耦合网络(coupled gradient network)求解混合整数规划问题,在此基础上 Walsh 等^[145~146]提出了广义 Hopfield 网络来求解混合整数问题,这方面文献相对较少,目前还在发展之中。

5.2.1 模型预测控制的表示

假设系统的线性离散时间状态空间模型为:

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) + g\omega(t) \\ y(k) &= Cx(k) + \omega(t) \end{aligned} \quad (5.1)$$

式中, $x \in R^n$ 是 n 维状态变量, $u \in R^m$ 是 m 维控制变量, $y \in R$ 是 l 维输出变量。 $\omega(k)$ 为测量误差,即:

$$\omega(k) = y(k) - Cx(k) \quad (5.2)$$

对于基本的模型预测控制,假设系统模型是线性的,优化目标函数是二次的,约束是线性不等式的形式,信号 $u(k+j|k)$ 是指 k 时刻预测的控制变量 u 未来 $k+j$ 时刻的值;信号 $x(k+j|k)$ 和 $y(k+j|k)$ 分别表示 k 时刻预测的状态变量 x 和输出变量 y 未来 $k+j$ 时刻的值。这些预测是在遵从系统模型 (5.1) 和假设控制输入 $u(k+i|k)$ ($i=0,1,\dots,j-1$) 已经作用的前提下给出的。

考虑如下问题,假设 k 时刻状态变量的初始值已知,要求得一控制序列 $u(k+j)_{j=0}^{N-1}$, 则有如下最优化问题:

$$\min_u J = \sum_{j=1}^N \left(y(k+j|k) - y_r \right)^T Q \left(y(k+j|k) - y_r \right) \quad (5.3a)$$

$$+ \sum_{j=0}^{N_c-1} \left(u(k+j|k) - u_r \right)^T P \left(u(k+j|k) - u_r \right)$$

$$y_{\min} \leq y(k+j|k) \leq y_{\max} \quad j=0, \dots, N \quad (5.3b)$$

$$u_{\min} \leq u(k+j|k) \leq u_{\max} \quad j=0, \dots, N_c-1 \quad (5.3c)$$

式中, N 是预测时域, N_c 是控制时域, y_r 和 u_r 分别是输出变量和控制变量的参考轨迹, $Q \in R^{n \times n}$ 和 $P \in R^{m \times m}$ 是权重。

模型预测控制在 k 时刻解决这个问题时需要计算出控制变量 $u(k+j|k)$ 所有的未来时刻的 N 个值。按照系统模型 (5.1), 有:

$$\begin{aligned} y(k+j|k) = & CA^j x(k) + \sum_{i=1}^j CA^{j-i} Bu(k+i-1|k) + \\ & \sum_{i=2}^j CA^{j-i} g\omega(k+i-1|k) + \omega(k+j|k) + CA^{j-1} g\omega(k) \end{aligned} \quad (5.4)$$

由式 (5.4) 可知, 等式右边第三、四项是 k 时刻以后的白噪声序列, 因此, $y(k+j|k)$ 的预报可表示为:

$$\hat{y}(k+j|k) = CA^j \hat{x}(k) + \sum_{i=1}^j CA^{j-i} B\Delta u(k+i-1|k) + CA^{j-1} g\hat{\omega}(k) \quad (5.5)$$

式中, $\hat{x}(k)$ 是 $x(k)$ 的估计值, $\hat{\omega}(k)$ 是 $\omega(k)$ 的估计值。

而根据式 (5.2) 有:

$$\hat{\omega}(k) = y(k) - C\hat{x}(k) \quad (5.6)$$

$\hat{x}(k)$ 的估计值 $\hat{x}(k)$ 采用修正的 Kalman 滤波方法计算, 即:

$$\begin{aligned} \hat{x}(k+1) = & (A - gC) \hat{x}(k) + B\Delta u(k) + gy(k) + \\ & k(k+1|k)[y(k+1) - C(A - gC) \hat{x}(k) - CB\Delta u(k) - Cgy(k)] \end{aligned} \quad (5.7)$$

$k(k+1)$ 是 Kalman 滤波器增益向量, 可由以下递推方程得到:

$$k(k+1) = \frac{(A - gC)P(k)(A - gC)^T C}{\sigma + C(A - gC)P(k)(A - gC)^T C} \quad (5.8)$$

$$P(k+1) = (A - gC)P(k)(A - gC)^T - k(k+1)C(A - gC)P(k)(A - gC)^T \quad (5.9)$$

式中, σ 是一个正的常数。

式 (5.8) 和式 (5.9) 的初值条件是 $P(0)$, 表示初始状态估计误差的协方差, 即:

$$P(0) = \psi \{(\hat{x}(0) - \bar{x}(0))(\hat{x}(0) - \bar{x}(0))^T\} \quad (5.10)$$

当 $k \rightarrow \infty$ 时, Kalman 滤波器可以收敛为一个稳态滤波器, 即如果 $(A - gC)$ 的特征值小于 1, 则有:

$$\lim_{k \rightarrow \infty} k(k+1) = 0$$

式 (5.7) 变为:

$$\hat{x}(k+1) = (A - gC)\hat{x}(k) + B\Delta u(k) + gy(k) \quad (5.11)$$

即 $\hat{x}(k)$ 可以由式 (5.11) 给出的渐进估计器计算。

将式 (5.6) 代入式 (5.5) 有:

$$\hat{y}(k+j|k) = CA^j(A - gC)\hat{x}(k) + \sum_{i=1}^j CA^{j-i}B\Delta u(k+i-1|k) + CA^{j-1}gy(k) \quad (5.12)$$

定义

$$Y(k) = \begin{bmatrix} \hat{y}(k+1|k) \\ \hat{y}(k+2|k) \\ \vdots \\ \hat{y}(k+N|k) \end{bmatrix}$$

$$U(k) = \begin{bmatrix} \Delta u(k) \\ \vdots \\ \Delta u(k + N_c - 1 | k) \end{bmatrix}$$

则式 (5.12) 可写成:

$$Y(k) = \begin{bmatrix} CB & 0 & 0 & \cdots & 0 \\ CAB & CB & 0 & \cdots & 0 \\ CA^2B & CAB & CB & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & 0 \\ CA^{N_c-1}B & CA^{N_c-2}B & CA^{N_c-3}B & \cdots & CB \end{bmatrix} U(k) + \begin{bmatrix} CA \\ CA^2 \\ \vdots \\ CA^N \end{bmatrix} \begin{bmatrix} (A - gC)\hat{x}(k) + gy(k) \end{bmatrix} \quad (5.13)$$

$$= \Gamma U(k) + \Phi$$

式中,

$$\Phi = \begin{bmatrix} CA \\ CA^2 \\ \vdots \\ CA^N \end{bmatrix} \begin{bmatrix} (A - gC)\hat{x}(k) + gy(k) \end{bmatrix} \quad (5.14)$$

$$\Gamma = \begin{bmatrix} CB & 0 & 0 & \cdots & 0 \\ CAB & CB & 0 & \cdots & 0 \\ CA^2B & CAB & CB & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & 0 \\ CA^{N_c-1}B & CA^{N_c-2}B & CA^{N_c-3}B & \cdots & CB \end{bmatrix} \quad (5.15)$$

可以将式 (5.3) 中的目标函数改写为:

$$\begin{aligned} J &= (Y(k) - y_r)^T Q (Y(k) - y_r) + (U(k) - u_r)^T P (U(k) - u_r) \\ &= (\Gamma U(k) + \Phi - y_r)^T Q (\Gamma U(k) + \Phi - y_r) + (U(k) - u_r)^T P (U(k) - u_r) \\ &= U(k)^T (\Gamma^T Q \Gamma + P) U(k) + 2[(\Phi - y_r)^T Q \Gamma - u_r^T P] U(k) \\ &\quad + (\Phi - y_r)^T Q (\Phi - y_r) + u_r^T P u_r \end{aligned}$$

上式可以简写为:

$$J = \frac{1}{2} U(k)^T H U(k) + f U(k) + \text{con} \quad (5.16)$$

式中,

$$H = \Gamma^T Q \Gamma + P \quad (5.17a)$$

$$f = 2[(\Phi - Y_r)^T Q \Gamma - u_r^T P] \quad (5.17b)$$

$$\text{con} = (\Phi - Y_r)^T Q (\Phi - Y_r) + u_r^T P u_r \quad (5.17c)$$

式 (5.3b) 和式 (5.3c) 可以改写为:

$$\begin{bmatrix} \Gamma^T (Y_{\min} - \Phi x(k)) \\ U'_{\min} \end{bmatrix} \leq \begin{bmatrix} U(k) \\ U(k) \end{bmatrix} \leq \begin{bmatrix} \Gamma^T (Y_{\max} - \Phi x(k)) \\ U'_{\max} \end{bmatrix} \quad (5.18)$$

式中, $Y_{\min} = [y_{\min} \cdots y_{\min}]^T$ 和 $Y_{\max} = [y_{\max} \cdots y_{\max}]^T$ 是 $l \times 1$ 矩阵, $U'_{\min} = [u_{\min} \cdots u_{\min}]^T$ 和 $U'_{\max} = [u_{\max} \cdots u_{\max}]^T$ 是 $m \times 1$ 矩阵。

定义

$$U_{\min} = \max \{ \Gamma^T (Y_{\min} - \Phi x(k)), U'_{\min} \} \quad (5.19a)$$

$$U_{\max} = \min \{ \Gamma^T (Y_{\max} - \Phi x(k)), U'_{\max} \} \quad (5.19b)$$

则式 (5.18) 可改写为:

$$U_{\min} \leq U(k) \leq U_{\max} \quad (5.20)$$

因此解式 (5.3) 表示的最优化问题即解如下有约束最优化问题:

$$\min_{U(k)} J = f(U) = \frac{1}{2} U(k)^T H U(k) + f^T U(k) \quad (5.21)$$

$$U_{\min} \leq U(k) \leq U_{\max}$$

式 (5.21) 表示的最优化问题是一个标准的二次规划 (QP) 问题。但是式 (5.21) 的解和初始值 $x(k)$ 密切相关, 要实现模型预测控制, 就要在每一个采样时刻在线求解 QP 问题。所以 QP 问题的求解时间必须小于采样时间。虽然有一些高效的 QP 求解方法, 如积极集法等, 但是 QP 问题的求解还是不够快。正是基于这个原因, 模型预测控制方法一般应用于化工、生物等反应过程比较长、

采样时间比较长的慢系统控制中。将模型预测控制应用到燃料电池系统这种采样时间比较短的快系统中就面临 QP 的计算效率问题。为了解决这个问题，将模型预测控制应用到燃料电池系统中，本节提出了基于回归神经网络的优化方法来解决这个问题。

5.2.2 基于回归神经网络优化的模型预测控制的体系结构

在每一采样时间式 (5.21) 中的 $x(t)$ 已知，因此应用文献^[152]中的方法来求解 QP 问题。

式 (5.21) 的拉格朗日函数为：

$$L(U, x, \eta) = f(U) - x^T(U - \eta) \quad (5.22)$$

式中， $x \in R^{mN_c}$ 是拉格朗日乘子， $\eta \in X = \{x \in R^{mN_c} \mid U_{\min} \leq x \leq U_{\max}\}$ 。按照鞍点理论^[147]，当 U^* 是式 (5.21) 的优化解时，假设 x 和 η 的值是 λ^* 和 η^* 。

参考文献^[142]中提出的将 QP 问题转化为回归神经网络的方法，得出如下的动态方程。

$$\text{状态方程: } \frac{dv}{dt} = \lambda \{ P_x(Wv + q - v) - Wv - q \} \quad (5.23)$$

$$\text{输出方程: } U(t) = Rv(t) + a \quad (5.24)$$

式中， $W = R = H^{-1}$ ， $q = a = -H^{-1}f$ ， $v \in R^{mN_c}$ 是回归神经网络的状态变量， $\lambda > 0$ 是常数。

定义 $P_x(v) = [P_x(v_1), P_x(v_2), \dots, P_x(v_{mN_c})]^T$ ， $i = 1, \dots, mN_c$ ，则有：

$$P_x(v_i) = \begin{cases} U_{\min}(i) & v_i < U_{\min}(i) \\ v_i & U_{\min}(i) \leq v_i \leq U_{\max}(i) \\ U_{\max}(i) & v_i > U_{\max}(i) \end{cases} \quad (5.25)$$

式 (5.21) 转化而来的回归神经网络可以用单层结构的模拟电路来实现，考虑到采样的每一步都要进行基于回归神经网络的优化求解，基于回归神经网络优化的模型预测控制结构框图如图 5.1 所示。图中， $p = mN_c$ ，电路中包含 $p^2 + 2p + 2$ 个加法、 p 个

积分和 p^2 个权重连接, 映射操作 $P_X(v_i)$ 用一个线性分段函数来实现; Mux 表示将多个信号 v_i 转换成一个总线信号 V ; Demux 表示将一个总线信号 V 分成多个信号 v_i ; Selector 表示从一个总线信号 $U(k)$ 中取出前 m 个。

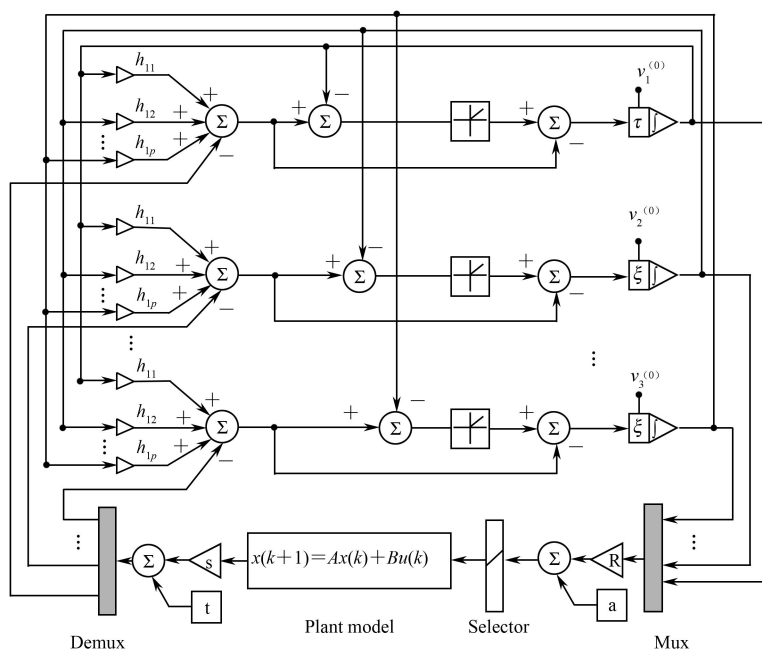


图 5.1 基于回归神经网络优化的模型预测控制结构框图

基于回归神经网络优化的模型预测控制算法如下:

① 初始化。令 $k=1$, 设定终止时间 T_{end} , 获取系统模型的状态变量 $x(k)$ 、预测时域 N 、控制时域 N_c 、采样时间 t 、权重 Q 和 P 、每一采样时刻的回归神经网络优化计算时间 Δt 。按照系统模型和前面的公式, 计算矩阵 Φ , Γ , H , f 和 $W=R=H^{-1}$ 。

② 计算回归神经网络参数。计算 $q=a=-H^{-1}f$, 按照式

(5.19) 计算控制变量的上限 U_{\max} 和下限 U_{\min} 。

③ RNN 动态优化。根据 W , R , q 和 a , 回归神经网络开始运行, Δt 时间后, 得到稳态值 U^* 。

④ 系统模型的预测输出。取出上一步计算出来的最优控制变量 U^* 的前 m 个作为系统模型的控制变量, 按照系统模型, 计算下一步的状态变量 $x(k+1)$ 。

⑤ 如果 $k < T_{\text{end}}$, 则设 $k=k+1$, 返回第二步; 否则算法结束。

5.2.3 收敛性分析

为了研究基于回归神经网络优化的模型预测控制的优化性能, 必须研究每一采样时间的回归神经网络的收敛特性。

定义: 在每一采样时间对于求解式 (5.21) 的优化解 \bar{v}^* 的回归神经网络, 如果存在一个时间 τ_0 , 使得对于时间 $t \geq \tau_0$ 系统的输出轨迹 $v(t)$ 达到 \bar{v}^* , 则称该神经网络对式 (5.21) 是有限时间收敛的; 如果一个回归神经网络的输出轨迹 $v(t)$ 满足

$$\|v(t) - \bar{v}^*\|^2 \leq c_0 e^{-\eta(t-t_0)}, \quad \forall t > t_0$$

式中 η 是独立于初始状态点的正常数, c_0 是依赖于初始状态点的正常数, 则称该回归神经网络是指数收敛的。

对于前述的基于回归神经网络的模型预测控制的收敛问题, 主要结论如下。

定理 1: 在每一采样时间对于求解式 (5.21) 的优化解问题, 回归神经网络的状态轨迹是全局收敛的。

证明: 对于任意给定的初始点 $v(t_0) = v_0$, 令 $v(t)$ 是式 (5.23) 中定义的状态轨迹。

考虑如下的李亚普诺夫函数:

$$V(v) = \frac{1}{2} \|G(v - \bar{v}^*)\|^2$$

式中, \bar{v}^* 是式 (5.23) 的平衡点, G 是一个对称的正定矩阵, 满

足 $G^2 = (I + W)$ ，则

$$\begin{aligned} \frac{d}{dt} V(v) &= \left(\frac{dV}{dv} \right)^T \frac{dv}{dt} \\ &= \lambda(v - v^*) G^2 \{ P_X(Wv + q - v) - Wv - q \} \end{aligned}$$

按照文献^[142, 147]中的结果，有

$$\{ P_X(Wv - q - v) - Wv^* - q \}^T \{ (v - v^*) - P_X(Wv - q - v) - Wv^* - q \} \geq 0$$

则

$$\begin{aligned} &(v - v^*)(I + W) \{ P_X(Wv + q - v) - Wv - q \} \\ &\leq -(v - v^*)^T W(v - v^*) - \| P_X(Wv + q - v) - Wv - q \|^2 \end{aligned}$$

于是有

$$\frac{d}{dt} V(v) \leq -\lambda(v - v^*)^T W(v - v^*) - \lambda \| P_X(Wv + q - v) - Wv - q \|^2 \leq 0$$

因此，在每一采样时间对于求解式 (5.21) 的优化问题，回归神经网络的状态轨迹是全局收敛的。

定理 2：如果 λ 的值足够大，在每一采样时间式 (5.21) 的回归神经网络收敛时间是有限的。

证明：令

$$f(v(t)) = \| P_X(Wv + q - v) - Wv - q \|^2$$

则有 $f(v(t)) \geq 0$ 和 $f(v(t_0)) \geq 0$ ，因为 $f(v(t))$ 是连续的^[157]，所以存在 $\tau > 0$ 和 $\delta > 0$ ，使得对于任意 $t \in [t_0, t_0 + \tau)$ ， $f(v(t)) \geq \delta$ 。

按照定理 1，

$$\begin{aligned} \frac{d}{dt} V(v) &\leq -\lambda(v - v^*)^T W(v - v^*) - \lambda \| P_X(Wv + q - v) - Wv - q \|^2 \\ &\leq -\lambda \| P_X(Wv + q - v) - Wv - q \|^2 \end{aligned}$$

则有

$$\begin{aligned} V(v(t)) &\leq V(v(t_0)) - \lambda \int_{t_0}^t \| P_X(Wv(s) + q - v(s)) - Wv(s) - q \|^2 ds \\ &\leq V(v(t_0)) - \lambda \int_{t_0}^{\tau+t_0} f(v(s)) ds \leq V(v(t_0)) - \lambda \delta \tau \end{aligned}$$

令

$$\lambda = \frac{V(v(t_0))}{\delta\tau}$$

当 $t \geq t_0 + \tau$ 时, 有

$$V(v(t)) \leq V(v(t_0)) - \lambda\delta\tau = 0$$

因此, 如果 λ 的值足够大, 在每一采样时间式 (5.21) 的回归神经网络收敛时间是有限的。

定理 3: 如果 $W = H^{-1}$ 是对称和半正定的, 则在每一采样时间对于式 (5.21) 所提出的回归神经网络是全局指数收敛的。

证明: 在式 (5.21) 中 $W = H^{-1}$ 肯定是对称和半正定的, 因此 $V(v) \geq \alpha \|v - v^*\|^2 / 2$, 其中 $\alpha > 0$ 是 H 的最小特征值, 而且存在 $\mu > 0$ 使得

$$(v(t) - v^*)^T W(v(t) - v^*) \geq \mu \|v(t) - v^*\|^2$$

因为

$$\begin{aligned} \frac{d}{dt} V(v) &\leq -\lambda(v - v^*)^T W(v - v^*) - \lambda \|P_X(Wv + q - v) - Wv - q\|^2 \\ &\leq -\lambda(v - v^*)^T W(v - v^*) \end{aligned}$$

则

$$\frac{d}{dt} V(v) \leq -\lambda\mu \|v - v^*\|^2 \leq -\frac{2\lambda\mu}{\alpha} V(v)$$

则有

$$\|v - v^*\|^2 \leq V(v(t_0)) e^{-\psi(t-t_0)}$$

式中, $\psi = 2\lambda\mu/\alpha$ 。

因此, 在每一采样时间式 (5.21) 所提出的回归神经网络是全局指数收敛的。 W 不依赖于 $x(t)$, 因此在每一采样时间本章所提出的神经网络收敛性不依赖于 $x(t)$, 但是从前面的分析可以看出, f 和 q 的值和 $x(t)$ 密切相关, 所以在每一采样时间回归神经网络的输出的收敛值和 $x(t)$ 密切相关。也就是说, 在每一采样时间控制变量的最优解和状态向量值密切相关。

5.2.4 仿真结果

本章提出的基于回归神经网络的模型预测控制用于燃料电池系统的水管理中。水管理的目标是将阴极的水浓度保持在一个合适的值并尽量避免水浓度的波动。按照第2章中的非线性模型,取出涉及水管理的5个状态变量 $x=[m_{H_2}, m_{O_{2,an}}, m_{O_2}, m_{N_2}, m_{O_{2,ca}}]^T$ 以及相关的方程,模型中用到的参数见表3.1,这些参数基于75千瓦的FORD P2000燃料电池车原型^[148],将这些公式用MATLAB中的Simulink实现,Simulink模型见第2章。该模型可以预测湿度对电堆电压的影响,可以用于燃料电池系统水管理控制的仿真中。下面看看对加湿器的加湿流量不加控制、进行简单的PID控制以及用本章提出的基于神经网络优化的预测控制这3种方法的仿真结果,在这3种方法中,假设空气流量得到很好的控制,在0~3秒期间进堆空气流量为0.4kg/s,在3~6秒期间进堆空气流量为0.6kg/s。

首先看看对加湿器中的水流量 W_{mj} 不加以控制的仿真结果。假设在0~3秒期间电堆电流为200A,在3~6秒期间电堆电流增至300A。在整个仿真期间(0~6秒)加湿水的流量为0.06kg/s,仿真结果如图5.2所示。从图5.2中可以看出,在0~3秒期间阴极的水质量大约为0.0021kg,而在3~6秒期间阴极的水质量下降到0.00186kg;电堆电压与之相对应,在0~3秒期间电堆电压为264V,在3~6秒期间电堆电压为208V。因此如果不控制加湿器加湿水流量,当电堆电流从200A增至300A时,阴极的水质量会突然下降,使得阴极的湿度不够,导致电堆电压也随之大幅度下降。




图 5.2 不加以控制的仿真结果

按照第 2 章所建立的非线性模型及第 3 章中的 Simulink 模型, 采用 PID 控制器来控制阴极的水质量, 控制变量是加湿器中加湿水的流量 W_{inj} 。在实际控制中阴极的水质量难以实际测量, 可以通过水管理模型建立阴极水质量的观测器, 具体方法可以参见文献[148]。同样, 在 0~3 秒期间电堆电流为 200A, 在 3~6 秒期间电堆电流增至 300A, 仿真结果如图 5.3 所示。图 5.3 中的第一幅图是电堆电压随时间变化图, 第二幅图是阴极水质量随时间变化图, 第三幅图是控制变量(加湿水流量)随时间变化图。从图 5.3 可以看出, 阴极水质量可以保持在一个稳定值, 大约为 0.0021kg; 在 0~3 秒期间电堆电压大约为 264V, 在 3~6 秒期间电堆电压大约为 240.5V; 当电堆电流阶跃上升时, 阴极水质量及电压的响应时间大约为 0.5 秒。由此可见, PID 控制可以调节阴极水的质量, 但调节时间有点长。




图 5.3 PID 控制的仿真结果

下面设计基于神经网络优化的预测控制器。首先在电堆电流为 200A，电堆温度为 338K 时，对非线性系统进行线性化，得到状态空间方程：

$$\dot{x} = Ax + Bu$$

$$y = Cx + Du$$

式中，状态变量 $x = [m_{H_2}, m_{w,an}, m_{O_2}, m_{N_2}, m_{w,ca}]^T$ ，输出变量 y 是阴极水质量，控制变量 u 是加湿水流量。

设输出参考值为 $y_r = 0.0021\text{kg}$ ，权重 $P=1$ ， $Q=10$ ，预测步数为 3 步，采样时间为 0.1 秒，将这些值代入式 (5.11) 中，就可以用基于神经网络优化的预测控制来控制阴极水流量。在该回归神经

网络中，有 3 个状态变量，每一采样时间内 RNN 输出的动态轨迹如图 5.4 所示。在图 5.4 中， x 为每一采样时刻回归神经网络的状态变量，它的收敛时间大约为 0.005 秒，大约只有采样时间的 1/20，所以回归神经网络足以求解每一采样时间内预测控制的优化问题，即满足实时性要求。当电流条件和风机控制条件与 PID 控制相同时，基于神经网络优化的预测控制仿真结果如图 5.5 所示。从图 5.5 中可以看出，阴极水质量可以保持在 0.0021kg；在 0~3 秒期间电堆电压大约为 264V，在 3~6 秒期间电堆电压大约为 240.5V；当电流从 200A 跳至 300A 时，响应时间大约为 0.15 秒。将 PID 控制和基于神经网络优化的预测控制相比较，可以看出，后者比前者的响应时间短了很多，这对保持电堆内的湿度条件、提高质子交换膜的寿命很有帮助。




图 5.4 每一采样时间内 RNN 输出的动态轨迹




图 5.5 基于神经网络优化的预测控制仿真结果

仿真结果表明，基于神经网络优化的模型预测控制可以保持阴极水浓度，降低阴极湿度的波动，从而提高燃料电池系统输出电压，提高燃料电池寿命。与无控制和 PID 控制仿真结果相比较，基于神经网络优化的模型预测控制有较短的响应时间、较小的湿度波动，且能用于燃料电池的实时控制中。

5.3 基于湿度软测量的 PEMFC 水管理

针对前面讲的 PEM 燃料电池电堆所具有的各种特性，这里采用模糊神经网络控制系统来实现对电堆湿度的控制，由于它兼有神经网络和模糊控制逻辑的优点，所以在目前来说，它是针对这类具有时变性、大滞后、不确定性和非线性的强耦合系统的最佳控制策略。考虑到控制器实现的简易性和快速性，在设计中采用

了二维的控制器结构形式，将系统误差 E 和误差变化率 ΔE 作为输入语言变量，因此该控制系统具有常规 PD 控制器的作用。基于模糊神经网络的电堆湿度控制系统结构如图 5.6 所示。

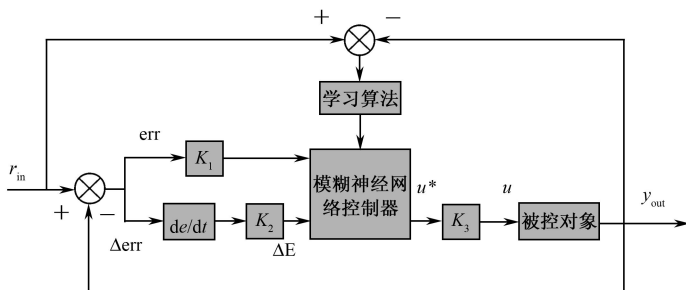


图 5.6 基于模糊神经网络的电堆湿度控制系统结构

其中， r_{in} 为系统的设定值； y_{out} 为系统的实际输出； u^* 为控制器的输出； u 为实际的控制值，包括风机的转速、外部加湿器加湿气体的温度和相对湿度^[149]。而图中的 K_1 、 K_2 表示比例因子， K_3 表示量化因子。因为在模糊控制逻辑中，通常把控制器的输入变量误差及误差变化的实际范围称为这些变量的基本论域（精确量），但是要进行模糊化处理，必须将输入变量从基本论域转换到相应的模糊集的论域，所以必须将输入变量乘以相应的比例因子，而输出变量则同样需要乘以相应的量化因子。在实际的测试系统中，设误差的基本论域为 $[\tilde{x}_1, +x_1]$ ，误差变化的基本论域为 $[\tilde{x}_2, +x_2]$ ，被控对象实际要求的变化范围即控制器输出变量的基本论域为 $[\tilde{u}, +u]$ 。如果模糊子集的论域选择分别为 $\{\tilde{n}, \tilde{n}+1, \dots, 0, \dots, \tilde{n}-1, \tilde{n}\}$ ， $\{\tilde{m}, \tilde{m}+1, \dots, 0, \dots, \tilde{m}-1, \tilde{m}\}$ ， $\{\tilde{l}, \tilde{l}+1, \dots, 0, \dots, \tilde{l}-1, \tilde{l}\}$ ，则比例因子和量化因子为：

$$K_1 = \frac{n}{x_1}, K_2 = \frac{m}{x_2}, K_3 = \frac{l}{u} \quad (5.26)$$

合理地选择比例因子和量化因子对整个控制器的最终性能是

非常重要的。其中，比例因子 K_1 、 K_2 的大小对控制系统的动态性能有影响。同前面所讲的 PID 控制器类似， K_1 影响系统的超调量， K_1 越大则系统的超调越大； K_2 影响系统的响应速度， K_2 越大则响应速度越慢，同时 K_2 对超调有很强的遏制作用。量化因子 K_3 作为控制器的总增益，它影响着控制器的输出及控制系统的特性，选择过小会使系统动态响应变慢，而选择过大则会使系统振荡加剧。

5.3.1 燃料电池电堆的湿度控制模型

根据 PEM 燃料电池的电化学反应过程和第 3 章实验结果的采集和分析，可以得到 PEM 燃料电池电堆的湿度主要和以下几个方面相关联：外部加湿器送入电堆的气体的温度和湿度、风机的转速、电堆的阻抗。电堆内部压力的影响相对较小，可以忽略不计。PEM 燃料电池电堆内部的水有以下几个来源：外部加湿器送来的气体的湿度、电堆内部化学反应生成的水、电堆内部气体流量带走的水。而相对来说，最主要的还是加湿器送入的气体温度和湿度以及化学反应生成的水。

在实验条件中，外部加湿器的基本工作过程是将空气送入露点加湿器内部，然后迅速将反应气加热到预设的露点温度值 t_d ，通过露点装置将容器内的空气精确地加湿到该温度下的水汽饱和状态，即相对湿度 $RH=100\%$ 。接着，将空气送到入口加热器，并将气体的温度控制在加热器的温度值 t_s ，此时空气的相对湿度可以通过以上两个温度值由经验公式计算出来：

$$RH = \frac{\ln E_0 + A \cdot t_s (B + t_s)}{\ln E_0 + A \cdot t_s (B + t_d)} \times 100\% \quad (5.27)$$

式中， E_0 为 0°C 时的饱和水汽压，取 6.11213hPa ； A 、 B 为经验系数，参照 Magnus 公式分别取为 17.62 和 243.12。

如此看来，电堆内部的湿度和参加空气的温度联系紧密，空气的温度成为影响气体湿度的重要因素。

同时, PEM 的电导率 σ 随含水量 λ_w 几乎呈正比变化, 随温度变化是一种非线性关系, 要获得单片 PEM 中的含水量 λ_w , 只要测量 PEM 欧姆电阻 R_w 和温度 T 即可。

第 3 章软测量得到的数据是单片电池含水量 λ_w , 表示单片 PEM 的水分子的含量。这里需要进行含水量和湿度的转化。

$$W = f / \lambda_w \times 100\% \quad (5.28)$$

式中, W 为相对湿度; f 为空气中水蒸气的绝对含量 (绝对湿度), 单位为 g/m^3 , 可以通过查表得到; λ_w 为在同一温度下空气中的饱和水蒸气量 (相对湿度), 单位为 g/m^3 。

从第 2 章的数据分析结果可以知道, 影响内阻变化的主要因素是空气和阴极空气的温度、流量。综合以上分析, 可以推出 PEM 燃料电池电堆的湿度模型, 描述如下:

$$T(k+1) = \Phi[V(k), T(k)] \quad (5.29)$$

式中, $V(k)$ 为空气的流量, $T(k)$ 为电堆的工作温度。

根据以上湿度模型和对实际软测量数据的分析, 可得到 PEM 燃料电池电堆的湿度控制的模型, 经过辨识和简化, 最后得到了如下的 n 阶加纯滞后模型:

$$G(s) = \frac{Y(s)}{U(s)} = \frac{ae^{\tau s}}{(b_1 s + 1)(b_2 s + 1) \cdots (b_n s + 1)} \quad (5.30)$$

式中, $Y(s)$ 为电堆温度; $U(s)$ 为多输入参数, 包括氢气与氧气的流量, 以及空气的温度; s 为步长; τ 为滞后因子; a, b_1, b_2, \dots, b_n 为系统辨识常数, 均为有理实数。

5.3.2 控制系统的网络结构

作为整个控制系统核心部分的模糊神经网络控制器, 它实现模糊逻辑控制和参数自整定的功能。网络的具体结构如图 5.7 所示。

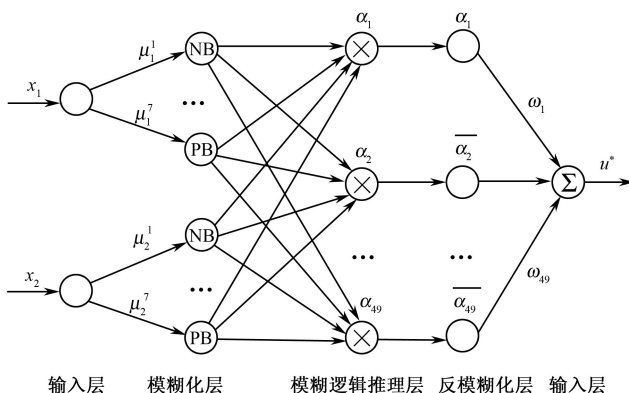


图 5.7 模糊神经网络结构

在图 5.7 中， x_1 和 x_2 分别表示空气的流量和温度。 u^* 表示最终测得的湿度值。

在上面的网络中，网络的两个输入量 x_1 和 x_2 对应于系统误差 E 和误差变化率 ΔE 。整个网络分为输入层、模糊逻辑层和输出层。输入层有两个神经元节点，起着传递信号的作用。输出层只有一个神经元节点，起着清晰化计算的功能。

输入层的输出为：

$$O_i^1 = x_i \quad (i=1, 2) \quad (5.31)$$

输出层的输入、输出为：

$$I^5 = \sum_{m=1}^{49} \omega_m \cdot O_m^4 \quad (5.32)$$

$$O^5 = f(I^5) \quad (5.33)$$

其中， I^i 为各层的输入量， O^i 为各层的输出量， $i=1, 2, \dots, 5$ 。

5.3.3 控制系统的模糊逻辑设计

模糊逻辑层设计为 3 个层次：模糊化、模糊逻辑推理及反模糊化，其主要功能和作用分别介绍如下。

1. 模糊化

模糊化处理就是将精确量转化为模糊量。在本系统中将系统误差 E 和误差变化率 ΔE 都分为 7 个语言值：

$E = \{NB, NM, NS, Z, PS, PM, PB\} = \{\text{负大}, \text{负中}, \text{负小}, \text{零}, \text{正小}, \text{正中}, \text{正大}\}$

$\Delta E = \{NB, NM, NS, Z, PS, PM, PB\} = \{\text{负大}, \text{负中}, \text{负小}, \text{零}, \text{正小}, \text{正中}, \text{正大}\}$

其中的每一个语言值对应一个模糊子集，而模糊子集所取的隶属函数为 Gaussian 型函数，因为它具有很多优点，特别是其表示简单且解析性能好，便于理论分析。

误差隶属函数为：

$$\mu(x_1) = \exp \left[- \left(\frac{x_1 - c_{1j}}{\sigma_{1j}} \right)^2 \right] \quad (j=1,2,\dots,7) \quad (5.34)$$

误差变化率隶属函数为：

$$\mu(x_2) = \exp \left[- \left(\frac{x_2 - c_{2j}}{\sigma_{2j}} \right)^2 \right] \quad (j=1,2,\dots,7) \quad (5.35)$$

该层的输入、输出为：

$$I_{ij}^2 = - \left(\frac{x_i - c_{ij}}{\sigma_{ij}} \right)^2 \quad (5.36)$$

$$O_{ij}^2 = \exp(I_{ij}^2) \quad (5.37)$$

2. 模糊逻辑推理

控制器按照语言控制规则进行模糊逻辑推理，相应的模糊控制规则形式是 Mamdani 型。

R_1 : if x_1 is A_1 and x_2 is B_1 then U^* is C_1 ;

R_2 : if x_1 is A_2 and x_2 is B_2 then U^* is C_2 ;

...

R_m : if x_1 is A_m and x_2 is B_m then U^* is C_m ;

其中，通常把 if 部分称为前提条件，而 then 称为结论， R_m 表示第 m 条规则。在本节中模糊控制器有 49 条规则，在给定前提参数 x_i ($i=1, 2$) 的情况下，可以得到如下的输出：

$$U^* = \frac{\sum_{m=1}^{49} [\mu A_m(x_1) \wedge \mu B_m(x_2)] \cdot C_m}{\sum_{m=1}^{49} [\mu A_m(x_1) \wedge \mu B_m(x_2)]} \quad (5.38)$$

式中，“ \wedge ”表示模糊取极小运算。

具体的模糊控制规则见表 5.1。

表5.1 模糊控制规则表

EC U E		~	~	~	~	~	~	0	1	2	3	4	5	6
		6	5	4	3	2	1	0	1	2	3	4	5	6
~ 6		6	6	5	5	4	4	3	3	2	2	1	1	0
~ 5		6	6	5	5	4	4	3	3	2	1	1	0	0
~ 4		6	6	5	5	4	3	3	3	2	1	0	~ 1	~ 1
~ 3		6	6	5	5	4	3	3	2	1	0	0	~ 1	~ 2
~ 2		6	6	5	5	4	3	2	1	0	0	~ 1	~ 2	~ 3
~ 1		6	6	5	5	3	2	1	0	0	~	~	~	~

										1	2	3	4
0	5	4	4	3	2	1	0	~	~	~	~	~	~
1	4	3	2	1	0	0	~	~	~	~	~	~	~
2	3	2	1	0	0	~	~	~	~	~	~	~	~

续表

	EC	~	~	~	~	~	~	0	1	2	3	4	5	6
		U	6	5	4	3	2	1	0	1	2	3	4	5
E														
3		2	1	0	0	1	2	3	3	4	5	5	6	6
4		1	1	0	1	2	3	3	3	4	5	5	6	6
5		0	0	1	1	2	3	3	4	4	5	5	6	6
6		0	1	1	2	2	3	3	4	4	5	5	6	6

该层的输入用来和模糊逻辑规则的前提条件相匹配，神经元的个数等于模糊规则的个数，然后完成模糊运算。

该层的输入、输出为：

$$I_{lk}^3 = O_l^2 O_{2k}^2 \quad (5.39)$$

$$O_m^3 = (I^3)_{ij} \quad (5.40)$$

式中， $l=1, 2, \dots, 7$ ， $k=1, 2, \dots, 7$ ， $m=1, 2, 3, \dots, 49$ 。

3. 反模糊化

反模糊化是将控制器的输出转化为精确量，神经元个数与上

一层相同。在本节中采用的是加权平均的方法。

该层的输入、输出为：

$$I_m^A = \sum_{m=1}^{49} O_m^3 \quad (5.41)$$

$$O_m^A = \frac{O_m^3}{I_m^A} \quad (5.42)$$

5.3.4 控制系统的学习算法

在本节的模糊神经网络中，可调参数有 3 类，第一类是输出层输出中的权值 ω_m ，它是第三、四层之间的加权系数，代表规则数。第二、三类可调参数则分别是 c_{ij} 和 σ_{ij} ，它们均位于第二层的 14 个节点中，分别代表了隶属函数的中心值和扩展常数。

由于模糊神经网络具有多层感知器的结构形式，其本质也是实现从输入到输出的非线性映射，可以仿照 BP 网络，用误差反传的方法来设计调整参数，以使被控对象的输出逼近期望输出。设期望输出为 $r_{in}(k)$ ，被控对象输出为 $y_{out}(k)$ ，性能指标为 J ，则

$$J = \frac{1}{2} [r_{in}(k) - y_{out}(k)]^2 \quad (5.43)$$

依据梯度下降最快的方法来修正网络的加权系数，并且附加一个动量因子，则模糊神经网络的权值和参数的修正值为：

$$\left. \begin{aligned} \omega_m(k+1) &= \omega_m(k) - \eta \frac{\partial J}{\partial \omega_m} + \alpha \Delta \omega_m(k) \\ c_{ij}(k+1) &= c_{ij}(k) - \eta \frac{\partial J}{\partial c_{ij}} + \alpha \Delta c_{ij}(k) \\ \sigma_{ij}(k+1) &= \sigma_{ij}(k) - \eta \frac{\partial J}{\partial \sigma_{ij}} + \alpha \Delta \sigma_{ij}(k) \end{aligned} \right\} \quad (5.44)$$

它们的梯度值为：

$$\left. \begin{aligned} \frac{\partial J}{\partial \omega_m} &= -\text{err}(k) O_m^4 \frac{\partial y_{\text{out}}(k)}{\partial u^*(k)} \\ \frac{\partial J}{\partial c_{ij}} &= -\text{err}(k) [\omega_m I_m^4 - I^5] (x_i - c_{ij}) \frac{O_m^3}{c_{ij}^2 (I_m^4)^2} \frac{\partial y_{\text{out}}(k)}{\partial u^*(k)} \\ \frac{\partial J}{\partial \sigma_{ij}} &= -\text{err}(k) [\omega_m I_m^4 - I^5] (x_i - \sigma_{ij}) \frac{O_m^3}{\sigma_{ij}^2 (I_m^4)^2} \frac{\partial y_{\text{out}}(k)}{\partial u^*(k)} \end{aligned} \right\} \quad (5.45)$$

式 (5.45) 中, $\frac{\partial y_{\text{out}}(k)}{\partial u^*(k)}$ 在被控对象未知的时候可以近似为:

$$\frac{\partial y_{\text{out}}(k)}{\partial u^*(k)} = \frac{y_{\text{out}}[u^*(k) + \Delta u^*(k)] - y_{\text{out}}[u^*(k)]}{\Delta u^*(k)} \quad (5.46)$$

综上所述, 网络训练的步骤可以归纳如下:

- ① 初始化, 将权值等设置为较小的随机数。
- ② 提供训练集, 给定输入向量和输出向量。
- ③ 计算实际输出, 按式 (5.31) ~ 式 (5.42) 分别计算各层神经元的输出。
- ④ 按式 (5.43) 计算目标值与实际输出值的误差。
- ⑤ 按式 (5.44) ~ 式 (5.46) 计算修正值。
- ⑥ 返回步骤②重复计算, 直到性能指标 J 满足要求为止。

5.3.5 仿真结果

基于模糊神经网络的 PEM 燃料电池电堆湿度控制系统, 其实现方法如第 4 章所述。偏差的基本论域为 $[0, 100]$, 偏差变化的基本论域为 $[4, 4]$, 输出变量的基本论域为 $[2, 2]$, 以上各变量的论域均为 $[6, 5, 4, 3, 2, 1, 0, 1, 2, 3, 4, 5, 6]$, 偏差、偏差变化和输出的量化等级均为 6, 则根据式 (5.26) 可得量化因子和比例因子:

$$K_1=0.5, K_2=1.6, K_3=2.5.$$

隶属函数的数据中心、扩张常数及连接权值均初始化为较小

的随机值，训练时的学习步长 η 取为 0.5，动量因子 α 取为 0.95。确定好这些参数以后，就可以通过 MATLAB 函数来实现这个模糊神经网络控制器，如图 5.8 所示是用 Simulink 构造的模糊神经网络仿真模型。




图 5.8 模糊神经网络仿真模型

本节中的被控对象为式 (5.30) 的 n 阶加纯滞后模型，考虑到控制中普遍存在的随机扰动，在对象中加入一个扰动项 $n(s)$ ，此时的传递函数为：

$$G(s) = \frac{ae^{-\tau s}}{(b_1 s + 1)(b_2 s + 1) \cdots (b_n s + 1)} + n(s) \quad (5.47)$$

式中， $n(s)$ 是随机噪声，在仿真实验中用白噪声代替。选取 1kW 级 PEM 燃料电池电堆的传递函数的参数为： $a=0.7$ ， $\tau=5$ ， $b_1=5.5$ ， $b_2=4.5$ ， $b_3=3.5$ ， $b_4=2.5$ ， $b_5=1.5$ 。用 MATLAB 进行仿真，得到的仿真曲线如图 5.9 所示，图中作为对比的是常规 PID 控制方式。




图 5.9 PEM 燃料电池电堆湿度控制仿真曲线

从图中可以看出,在整个控制性能上,包括最大超调量、调整时间及稳态性,模糊神经网络都明显优于普通的PID控制器,它不仅反应快速,超调量小,而且收敛后的波动小,波动范围不到整体的5%。

下面再来看看当被控系统的参数改变的时候,控制系统会有怎样的反应。在实验中,将传递函数的参数 a 分别小幅度改变为 1 和大幅度改变为 2,仿真曲线分别如图 5.10 和图 5.11 所示。




图 5.10 $a=1$ 时的 PEM 燃料电池电堆湿度控制仿真曲线




图 5.11 $\alpha=2$ 时的 PEM 燃料电池电堆湿度控制仿真曲线

从图 5.10 和图 5.11 中可以看出, 常规 PID 控制器对被控对象的参数变化非常敏感, 而模糊神经网络控制器则对参数变化反应不明显。如图 5.11 所示, 当被控对象参数的变化幅度再次增大, 常规 PID 已经不能适应新的工作条件, 不仅超调量非常大, 而且长时间大幅度波动, 即使最后稳定, 波动范围也超过 15%。相对而言, 模糊神经网络虽然也出现了较大的超调和较小的波动, 但系统能很快稳定下来, 稳态时波动也小, 波动范围不超过整体的 8%。

由此可以看出, 如果采用神经网络模糊控制, 可以很快地让系统处于稳态, 相对于采用 PID 控制来说, 它的性能有了很大的提高。尤其是在出现误差、需要很快达到稳态的情况下, 它能获得比较大的控制速度, 并且对于结构或者参数的变化(扰动)能及时地自我调整, 从而很快地重新回到稳态。

根据以上分析, 可以得出以下几点结论:

① 本节采用的模糊神经网络不仅具有良好的模糊规则优化调整能力, 还具有快速的学习能力, 以及知识的判断与抉择的能力。

② 模糊神经网络控制的 PEM 燃料电池电堆湿度控制系统, 通过神经网络的学习能力和模糊控制的知识表达能力来调整各个参数, 从而实现对电堆湿度很好的控制。

③ 模糊神经网络控制系统在电堆湿度对象变化时, 依然保持良好的控制品质, 表现了该控制系统的良好鲁棒性、动态特性和抗干扰能力。所以综合来说, 相对于其他控制方法, 模糊神经网络控制器更符合 PEM 燃料电池电堆湿度控制系统这类具有时变性、大滞后、不确定性和非线性的强耦合系统的要求。

第6章 质子交换膜燃料电池系统控制

前两章分别讨论了空气供应系统的控制和水管理的控制问题，为燃料电池系统控制打下了基础。但燃料电池系统是一个多输入/多输出的系统，系统中温度、湿度和空气流量之间相互耦合，将它们单独控制难以达到提高系统功率及寿命的目标。本章提出燃料电池系统多输入/多输出控制方法。

6.1 概 述

现在有很多学者对燃料电池系统的控制进行了研究。但这些研究大多是单变量控制或对燃料电池中某一子系统进行控制，如有的文献^[150]对空气供应子系统进行控制，有的文献^[151]对温度进行控制，有的文献^[152]对湿度进行控制。但燃料电池系统是一个多输入/多输出、强耦合的非线性系统，各变量间相互影响，对单个变量进行控制难以取得好的效果。在燃料电池系统控制中，控制目标是使燃料电池系统的净输出功率最大。要满足这一控制目标，就要对燃料电池的电堆温度、湿度、氢气流量和进堆空气流量进行控制。在这4个控制变量中，氢气流量和其他控制变量间的耦合相对较弱，在实际控制时可以取一个适当高的固定值。电堆温度与电堆湿度和进堆空气流量有着密切的关系，但温度变化时间常数比较大，有一定的滞后，所以燃料电池的温度控制一般和电堆湿度、进堆空气流量的控制分开，即单独进行控制，控制目标一般是将电堆温度尽量控制在一个固定的范围内。电堆湿度和进堆空气流量两者动态变化的时间常数相差不大，两者相互影响。

从第3章中电堆湿度的影响因素分析可以看出,增大进堆空气流量会使燃料电池电堆湿度降低,使得电堆输出电压降低,所以不能只考虑加湿而不考虑进堆空气流量对加湿的影响。因此要对电堆湿度和进堆空气流量同时进行控制,提高燃料电池系统输出净功率,延长燃料电池的使用寿命。

6.2 国内外研究现状

6.2.1 传统方法

Lee 等人^[153]研制了一台 1kW 的 PEM 燃料电池,经由 DC/ AC 逆变器输出 220V 的电力。燃料电池的控制单元采用 PLC 作为主控设备,通过预先写入的逻辑来控制气体送给、冷却和热交换子系统,从而使系统能对外部负载变化做出响应,而不会出现燃料送给过多或缺乏。采用基于温度的 PID 控制来调节冷却水的送进速度,使电堆温度维持在设定范围内。他们还对比了燃料供给方法进行了分析,通过实验得到了负载电流变化时燃料供给流速的优化值。Mufford 等^[154]设计了可用来控制功率输出的控制系统,发电系统由燃料电池电堆和一系列电气负载(包括电机和速度可调的压缩机)组成,电堆的功率输出取决于压缩机的速度。控制系统参考传感器输入的电流信号,采用前向的控制信号调节压缩机速度,可以满足实时功率的需要。

6.2.2 预测控制

模型预测控制是一种优化控制策略,它就像人一样,根据头脑中对外部世界的了解,通过快速思维不断比较各种方案可能造成的后果,并从中择优予以实施,这一思想无疑是十分深刻的。

它首先根据已知的系统模型（可以是各种模型）预测未来一段时间（称为预测时域，predictive horizon）系统的行为，然后根据某个性能指标得出系统在控制时域（control horizon）中的最优的控制输入序列，并将控制输入序列的前几个采样周期（一般只用到一个输入）的值作为系统的实际控制输入，在下一采样周期重复此过程。因此模型预测控制又称为滚动时域控制（receding horizon control）。由于预测控制采用多步测试、滚动优化和反馈校正的控制策略，因而控制效果好，适用于控制不易建立精确数学模型且比较复杂的工业生产过程。在燃料电池系统控制中，有一些学者采用这种方法，如 Vahidi 等^[155]采用模型预测控制，设计了混合动力燃料电池汽车的空气供应系统控制器，满足了空气供应的快速响应性；Golbert 等^[156]将燃料电池模型线性化，用预测控制方法满足了功率的需求，但其预测模型是基于偏微分方程的解析模型，难以实际应用；Yuan^[157]等将一种基于支持向量机的预测控制方法用于燃料电池控制中。

6.2.3 模糊控制

模糊控制是一种基于规则的控制，它直接采用语言型控制规则，出发点是现场操作人员的控制经验或相关专家的知识，在设计中不需要建立被控对象的精确的数学模型，因而使控制机理和策略易于接受与理解，设计简单，便于应用。德国的 Schumacher^[158]采用模糊控制方法对微型 PEMFC 的水管理进行了控制；Abtahi^[126]采用基于 Mamadani 推理的模糊控制方法对燃料电池的水管理进行了控制。

6.2.4 神经网络控制

将燃料电池看做“黑箱”，根据实验所得数据，采用神经网络

的方法,建立燃料电池的模型。根据所得的模型,进行神经网络PID控制或神经网络自适应控制。Almeida^[159]提出了一种神经优化控制系统,采用参数化小脑神经模型控制器来控制系统的输出电压,该控制器允许用户设置性能指标。Azmy^[160]提出一种基于人工神经网络的方法,用来在线更新参数,实现优化管理和简化管理过程的目的。

6.2.5 自适应控制

燃料电池系统存在时变性和不确定性,对此可以采用自适应控制方法。20世纪50年代初,为设计高性能飞机自动驾驶仪提出了一种自动调整前馈增益的MIT方案,这是最初的自适应控制。自适应控制与常规的反馈控制和最优控制一样,也是一种基于数学模型的控制方法,所不同的只是自适应控制所依据的关于模型和扰动的先验知识比较少,需要在系统的运行过程中不断提取有关模型的信息,使模型逐步完善。具体地说,可以依据对象的输入、输出数据,不断地辨识模型参数,这个过程称为系统的在线辨识。随着生产过程的不断进行,通过在线辨识,模型会越来越准确,越来越接近实际。既然模型在不断地改进,显然,基于这种模型综合出来的控制作用也将随之不断地改进。在这个意义下,控制系统具有一定的适应能力。例如,在系统设计阶段,由于对象特性的初始信息比较缺乏,系统在刚开始投入运行时可能性能不理想,但是只要经过一段时间的运行,通过在线辨识和控制,控制系统会逐渐适应,最终将自身调整到一个满意的工作状态。再如,某些控制对象,其特性可能在运行过程中要发生较大的变化,但通过在线辨识和改变控制器参数,系统也能逐渐适应。自适应控制有两种最基本的类型,即“模型参考自适应控制”和“自校正调节器”,在这两种基本类型的基础之上,结合人工智能、人工生命等发展出了新型复杂自适应控制。Zhang^[150]等应用自

适应控制方法对燃料电池空气供应系统的时变参数进行了估计，配置了闭环系统的极点，最后设计了自适应控制器^[161]并在实验装置上进行了实验验证。Yang 等^[162]用氢气流量和空气流量的伪随机二进制序列作为输入激励燃料电池系统，测量燃料电池的电压和电流，用辨识的方法得到降阶的传递函数，而对未建模和高阶动态部分用辅助输入项来描述，最后应用自适应控制对燃料电池进行控制。当燃料电池工况变化不大时，自适应控制可以达到较好的控制性能，但工况变化复杂时就难以奏效。

6.2.6 鲁棒控制

鲁棒控制 (robust control) 方面的研究始于 20 世纪 50 年代。在过去的 20 年中，鲁棒控制一直是国际自控界的研究热点。所谓“鲁棒性”，是指控制系统在一定（结构、大小）的参数摄动下，维持某些性能的特性。根据对性能的不同定义，可分为稳定鲁棒性和性能鲁棒性。以闭环系统的鲁棒性作为目标设计得到的固定控制器称为鲁棒控制器。由于工作状态变动、外部干扰及建模误差的缘故，实际工业过程的精确模型很难得到，而系统的各种故障也将导致模型的不确定性，因此可以说模型的不确定性在控制系统中广泛存在。如何设计一个固定的控制器，使具有不确定性的对象满足控制品质，也就是鲁棒控制，成为国内外科研人员的研究课题。Sedghisigarchi 等^[163]设计了一个 H_∞ 控制器来调整负载变动情况下的燃料电池电压，通过控制氢气流量，输出电压变化可以保持在 5% 左右；Wang 等^[164~165]将鲁棒控制方法应用到单输入/单输出 PEMFC 系统中，通过调节氧气流量，稳定燃料电池的输出电压，实验结果显示鲁棒控制能够抗干扰，达到较好的性能；后来 Wang 等^[166]又将鲁棒控制推广到多变量鲁棒控制中。

从国内外研究来看，PEMFC 控制的研究经历了一个从无到有、从简单到复杂的过程。目前的发展趋势是从简单的 PID 控制向基于

模型的优化控制和智能控制的方向发展，它的难点是满足可操作性、耐久性和经济型的多输入/多输出控制，而且这些控制方法还要考虑到 PEMFC 控制的实际，需要满足实时性问题。所以研究提高燃料电池性能、经济性的实时控制方法是以后研究的方向。

6.3 质子交换膜燃料电池系统预测控制器设计

燃料电池发动机预测控制的设计思想，是将根据需求功率第一次计算得到的发动机输入控制量给燃料电池发动机预测模型，在芯片中预测出下一时刻系统的功率输出值，然后将预测功率输出值进行反馈调节，以此获得最优的输入控制量。其关键就在于，当实际功率还未真实输出时，预测模型就已经预测出了功率输出值，当输入控制量的时候，系统就已经省掉延时环节，跨时间直接开始调节操作参数了，这种控制策略可以节省系统的调节时间，使系统的输出快速达到目标值，达到提高系统响应速度的目的^[167]。

基于神经网络的燃料电池发动机预测控制结构如图 6.1 所示。

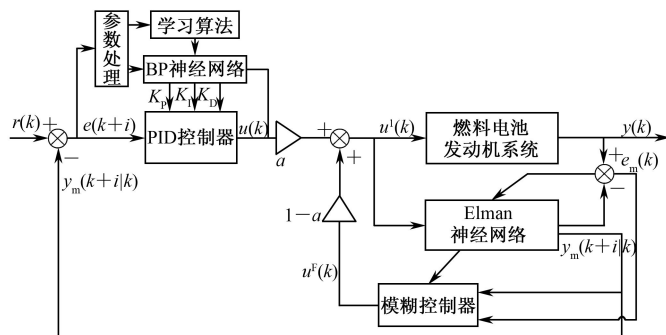


图 6.1 基于神经网络的燃料电池发动机预测控制结构

6.3.1 燃料电池发动机预测模型

目前最为流行的广义预测控制采用 CARIMA 差分方程作为预测模型, 多步输出预测需要在线递推求解 Diophantine 方程, 需要在线辨识预测差分方程和 Diophantine 方程的系数, 以及运算过程中的中间变量参数, 而且在滚动优化中又需要在线对矩阵进行求逆运算。计算工作量大, 实时性低, 不利于其在快速系统中的应用。并且燃料电池发动机系统是一个典型的非线性系统, 不能直接用 CARIMA 模型表示。所以, 本章采用前面第 4 章建立的 Elman 神经网络模型作为燃料电池发动机系统的预测模型, 本节将直接引用, 不再赘述。

由第 2 章可得到燃料电池发动机系统模型如下:

$$\begin{cases} y_m(k) = g \left(\sum_{j=1}^{S_2} w_j^{(3)} f \left(\sum_{i=1}^{S_1} w_{ji}^{(2)} u_i(k-1) + \sum_{l=1}^{S_2} w_{lj}^{(1)} x_l^c(k-1) + \theta^{(1)} \right) + \theta^{(2)} \right) \\ x^c(k) = x(k-1) = f(w^{(1)} \cdot x^c(k-1) + w^{(2)} \cdot u(k-2) + \theta^{(1)}) \end{cases} \quad (6.1)$$

式中, $y_m(k)$ 为燃料电池发动机系统模型在 k 时刻的输出, 有电压输出 V_{st} 和电堆温度输出 T_{st} ; $u_i(k)$ 为系统模型在 k 时刻的外部输入, 共有 8 个, 分别为空压机控制电压 V_{cm} 、循环水泵控制频率 f_p 、散热风扇控制电压 V_{fan} 、负载电流扰动 I_{st} , 以及电压输出 V_{st} 和电堆温度输出 T_{st} 在前一时刻的值及变化率; $x^c(k)$ 为承接层在 k 时刻的输出; $x(k)$ 为隐含层在 k 时刻的输出。

三个连接权值矩阵 $w^{(1)}$ 、 $w^{(2)}$ 、 $w^{(3)}$ 通过样本训练得到; 输入层节点个数 S_1 在燃料电池发动机系统模型中取为 8; 隐含层节点个数 S_2 经实验得到, 为 17; 输出层节点个数 S_3 为 2。

只要将神经网络的输出再代入 Elman 神经网络的输入, 反复迭代计算, 就可求出多步以后的预测值。计算步骤如图 6.2 所示。




图 6.2 Elman 神经网络多步预测计算步骤

Elman 神经网络预测输出的是电压值，预测出的电压值必须与给定的扰动电流值相乘，得到功率值，即为预测的功率输出值。

6.3.2 基于神经网络自适应 PID 的预测控制

滚动优化器可以采用一个在线修正参数的 PID 控制器来代替。此算法包含两个部分：一个是传统的 PID 控制器，直接对燃料电池发动机系统进行闭环控制，并且 3 个参数 K_p 、 K_i 、 K_d 为在线整定式；另一个是 BP 神经网络，根据燃料电池发动机系统的运行状态，对 PID 控制器的 3 个参数进行在线调节，以期达到燃料电池发动机系统预测功率输出紧紧跟随给定目标功率值的最优化。

数字 PID 控制器的控制算式为：

$$u(k) = u(k-1) + K_p[\alpha(k) - \alpha(k-1)] + K_i\alpha(k) + K_d[\alpha(k) - 2\alpha(k-1) + \alpha(k-2)] \quad (6.2)$$

对于非线性 PID 控制器， K_p 、 K_i 、 K_d 、 $u(k)$ 、 $\alpha(k)$ 间存在着一个非线性函数关系。PID 控制要取得好的控制效果，就必须在这变化无穷的非线性组合中找出比例、积分和微分最佳的关系。BP 神经网络具有逼近任意非线性函数的能力，而且结构和学习算法简单明确。可以通过 BP 神经网络的训练和学习，找到某一最优控制规律下的 K_p 、 K_i 、 K_d 。

这里选取三层神经网络结构。为充分反映输入 PID 控制器信

号的特性，其输入节点选为 4 个，对应着：

$$\begin{cases} x_1(k) = e(k) - e(k-1) \\ x_2(k) = e(k) \\ x_3(k) = e(k) - 2e(k-1) + e(k-2) \\ x_4(k) = u(k-1) \end{cases}$$

神经网络的输出节点有 3 个，分别对应 PID 控制器的 3 个可调参数 K_p 、 K_i 、 K_D 。隐含层神经元个数采用试凑法得出，最终确定为 12 个神经元。神经网络结构如图 6.3 所示。




图 6.3 神经网络结构

燃料电池发动机 BP 神经网络的输入层的输出为：

$$O_j^{(1)} = x(j) \quad (j=1,2,3,4) \quad (6.3)$$

隐含层的输入为：

$$I_i^{(2)}(k) = \sum_{j=1}^4 w_{ij}^{(2)} O_j^{(1)}(k) \quad (i=1,2,\dots,12) \quad (6.4)$$

隐含层的输出为：

$$O_i^{(2)}(k) = f[I_i^{(2)}(k)] \quad (i=1,2,\dots,12) \quad (6.5)$$

式中， $w_{ij}^{(2)}$ 为隐含层加权系数； $f(\bullet)$ 为激活函数，可取正负对称的 Sigmoid 函数：

$$f(\bullet) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6.6)$$

输出层的输入为：

$$I_l^{(3)}(k) = \sum_{i=1}^{12} w_{li}^{(3)} O_i^{(2)}(k) \quad (l=1,2,3) \quad (6.7)$$

输出层的输出为:

$$\left\{ \begin{array}{l} O_l^{(3)}(k) = g[I_l^{(3)}(k)], \quad (l=1,2,3) \\ O_1^{(3)}(k) = K_p \\ O_2^{(3)}(k) = K_I \\ O_3^{(3)}(k) = K_D \end{array} \right. \quad (6.8)$$

式中, $g(\bullet)$ 为激活函数, 由于 K_p 、 K_I 、 K_D 不能为负, 所以输出层神经元的激活函数取非负的 Sigmoid 函数:

$$g(\bullet) = \frac{1}{2}[1 + \tanh(x)] = \frac{e^x}{e^x + e^{-x}} \quad (6.9)$$

取性能指标函数:

$$J = \frac{1}{2}[r(k+1) - y(k+1)]^2 \quad (6.10)$$

采用梯度下降法, 按性能指标函数的负梯度方向调整各个权值, 则输出层连接权值的修改公式为:

$$\Delta w_{li}^{(3)}(k+1) = -\eta \frac{\partial J}{\partial w_{li}^{(3)}} \quad (6.11)$$

式中, η 为学习速率。

将性能指标函数 J 对 $w_{li}^{(3)}$ 求偏导, 可得:

$$\frac{\partial J}{\partial w_{li}^{(3)}} = \frac{\partial J}{\partial y(k+1)} \frac{\partial y(k+1)}{\partial u(k)} \frac{\partial u(k)}{\partial O_l^{(3)}(k)} \frac{\partial O_l^{(3)}(k)}{\partial I_l^{(3)}(k)} \frac{\partial I_l^{(3)}(k)}{\partial w_{li}^{(3)}} \quad (6.12)$$

由式 (6.7), 得:

$$\frac{\partial I_l^{(3)}(k)}{\partial w_{li}^{(3)}} = O_i^{(2)}(k) \quad (6.13)$$

由式 (6.8), 得:

$$\frac{\partial O_l^{(3)}(k)}{\partial I_l^{(3)}(k)} = g'[I_l^{(3)}(k)] \quad (l=1,2,3) \quad (6.14)$$

由式 (6.2), 得:

$$\begin{cases} \frac{\partial u(k)}{\partial O_1^{(3)}(k)} = e(k) - e(k-1) \\ \frac{\partial u(k)}{\partial O_2^{(3)}(k)} = e(k) \\ \frac{\partial u(k)}{\partial O_3^{(3)}(k)} = e(k) - 2e(k-1) + e(k-2) \end{cases} \quad (6.15)$$

由式 (6.10), 得:

$$\frac{\partial J}{\partial y(k+1)} = -[y_r(k+1) - y(k+1)] = \alpha(k+1) \quad (6.16)$$

所以由式 (6.12), 得:

$$\frac{\partial J}{\partial w_{li}^{(3)}} = \alpha(k+1) \frac{\partial y(k+1)}{\partial u(k)} \times \frac{\partial u(k)}{\partial O_l^{(3)}(k)} g'[I_l^{(3)}(k)] O_i^{(2)}(k) \quad (l=1,2,3) \quad (6.17)$$

$\frac{\partial y(k+1)}{\partial u(k)}$ 未知, 可用预测模型 $y_m(k+1)$ 替代 $y(k+1)$, 利用

Elman 神经网络模型进行递推求解。

由此可得 BP 神经网络输出层的加权系数计算公式为:

$$\begin{cases} \Delta w_{li}^{(3)}(k+1) = \eta \delta_i^{(3)} O_i^{(2)}(k) \\ \delta_l^{(3)} = e(k+1) \frac{\partial y(k+1)}{\partial u(k)} \times \frac{\partial u(k)}{\partial O_l^{(3)}(k)} g'[I_l^{(3)}(k)] \quad (l=1,2,3) \end{cases} \quad (6.18)$$

同理可以推得隐含层加权系数计算公式为:

$$\begin{cases} \Delta w_{ij}^{(2)}(k+1) = \eta \delta_i^{(2)} O_j^{(1)}(k) \\ \delta_i^{(3)} = f' \left[I_i^{(2)}(k) \right] \sum_{l=1}^3 \delta_l^{(3)} w_{li}^{(3)}(k) \quad i=(1,2,\dots,12) \end{cases} \quad (6.19)$$

对于 $y_m(k+1)$ 代替 $y(k+1)$ 的值, 因为燃料电池发动机预测模型采用的是 Elman 神经网络模型, 而该神经网络的权值是由输出与样本之间的误差函数 E 在线修正的, 因此网络的输出可认为是经过修正的 y_p 。对于输出偏差造成的控制量的误差也可通过模糊

推理的方法得到补偿控制量。


6.3.3 基于模糊推理的反馈校正技术

模型失配或其他扰动因素所造成的输出偏差会造成最终控制量的偏差，本小节通过模糊推理对控制量的偏差加以补偿。此方法有别于一般性的对预测模型输出的直接补偿。把最终得到的控制信号 $u_i^f(k)$ 看为两个组成部分：

$$u_i^f(k) = \alpha u_i(k) + (1 - \alpha) u_i^F(k) \quad (\alpha \in [0, 1]) \quad (6.20)$$

式中， $u_i(k)$ 为上节优化算法得到的控制量； $u_i^F(k)$ 为模糊推理得到的模糊控制量； α 为组合因子，文献[114]讨论了 α 的选值方法，这里根据燃料电池发动机系统实际操作情况，选取为 0.9。

采用一个二维模糊控制器，输入量为系统的偏差 e 和偏差的变化率 Δe ，输出量为燃料电池发动机系统的控制量。由于在发动机系统中，控制量有 4 个输出，本节决定利用模糊控制器本身的解耦特点，在控制结构上实现解耦，即将一个 2 输入、4 输出的模糊控制器，分解成 4 个 2 输入、单输出的模糊控制器，从而使问题简化。本节以其中一个控制量空压机控制电压 V_{cm} 为例，其他控制量相似处理。模糊控制器结构如图 6.4 所示。



其中， $\alpha(k) = y(k) - y_m(k)$ ， $\Delta\alpha(k) = \alpha(k) - \alpha(k-1)$ 。 $\alpha(k)$ 、 $\Delta\alpha(k)$ 和 $u_i^F(k)$ 的基本论域分别为 $[-100V, 100V]$ 、 $[-4V, 4V]$ 、 $[0,$

10V]。各自的模糊子集论域均设为 $\{\tilde{6}, \tilde{5}, \tilde{4}, \tilde{3}, \tilde{2}, \tilde{1}, 0, 1, 2, 3, 4, 5, 6\}$ ，量化等级均为6，把偏差和偏差变化率从基本论域转化到模糊子集论域中， $u_i^F(k)$ 的模糊子集则在解模糊化时应用。

输入、输出的变量的语言值均分为7个，{负大，负中，负小，零，正小，正中，正大}，用字母表示为{NB, NM, NS, Z, PS, PM, PB}。

采用三角形隶属函数，运用 MATLAB 的模糊控制工具，形成隶属函数图^[72]，如图 6.5 所示。




图 6.5 隶属函数图

利用隶属函数，形成 e 和 Δe 的隶属函数表，分别见表 6.1 和表 6.2。控制量 u 的隶属函数表见表 6.3。

表6.1 e 的隶属函数表

e	$\tilde{6}$	$\tilde{5}$	$\tilde{4}$	$\tilde{3}$	$\tilde{2}$	$\tilde{1}$	0	1	2	3	4	5	6
PB	0	0	0	0	0	0	0	0	0	0	0	0.5	1
PM	0	0	0	0	0	0	0	0	0	0.5	1	0.5	0
PS	0	0	0	0	0	0	0	0.5	1	0.5	0	0	0

第 6 章 质子交换膜燃料电池系统控制

Z	0	0	0	0	0	0. 5	1	0. 5	0	0	0	0	0
NS	0	0	0	0. 5	1	0. 5	0	0	0	0	0	0	0
NM	0	0. 5	1	0. 5	0	0	0	0	0	0	0	0	0
NB	1	0. 5	0	0	0	0	0	0	0	0	0	0	0

表6.2 Δe 的隶属函数表

Δe	\sim 6	\sim 5	\sim 4	\sim 3	\sim 2	\sim 1	0	1	2	3	4	5	6
PB	0	0	0	0	0	0	0	0	0	0	0	0. 5	1
PM	0	0	0	0	0	0	0	0	0	0. 5	1	0. 5	0
PS	0	0	0	0	0	0	0	0. 5	1	0. 5	0	0	0
Z	0	0	0	0	0	0. 5	1	0. 5	0	0	0	0	0
NS	0	0	0	0. 5	1	0. 5	0	0	0	0	0	0	0
NM	0	0. 5	1	0. 5	0	0	0	0	0	0	0	0	0
NB	1	0. 5	0	0	0	0	0	0	0	0	0	0	0

表6.3 u 的隶属函数表

u	\sim 6	\sim 5	\sim 4	\sim 3	\sim 2	\sim 1	0	1	2	3	4	5	6
PB	0	0	0	0	0	0	0	0	0	0	0	0.	1

												5	
PM	0	0	0	0	0	0	0	0	0	0.5	1	0.5	0
PS	0	0	0	0	0	0	0	0.5	1	0.5	0	0	0
Z	0	0	0	0	0	0.5	1	0.5	0	0	0	0	0
NS	0	0	0	0.5	1	0.5	0	0	0	0	0	0	0
NM	0	0.5	1	0.5	0	0	0	0	0	0	0	0	0
NB	1	0.5	0	0	0	0	0	0	0	0	0	0	0

根据专家经验制定模糊规则：如果 e 为正大， Δe 也为正大，说明燃料电池发动机系统模型误差有增大的趋势，那么可以推断由此计算得到的空压机控制参数太小，空压机控制电压应该增大，故 u 为正大；若 Δe 为负大，说明燃料电池发动机系统模型输出误差有减小的趋势，空压机控制电压应该降到最小，故 u 为正小；若 e 为正大， Δe 为零，说明误差变化趋势不变，空压机控制电压可以减小些，故 u 为正中。相反，如果 e 为负大， Δe 也为负大，那么可以推断空压机控制电压取得太大，应减小控制器的输出，故 u 为负大。用同样的分析方法得到其他条件下控制量的模糊校正规则，共制定了 50 条规则。模糊控制规则表见表 6.4。

表6.4 模糊控制规则表

	NB	NM	NS	Z	PS	PM	PB
PB	PS	PS	PM	PM	PM	PB	PB
PM	Z	Z	PS	Z	PM	PM	PB
PS	Z	Z	Z	Z	PS	PM	PM

Z	NS	Z	Z	Z	Z	PS	PM
NS	NM	NS	NS	Z	Z	Z	PS
NM	NB	NM	NM	NM	NS	Z	PS
NB	NB	NB	NM	NM	NS	NS	Z

通过模糊控制规则表可求出仍属于模糊集合控制量 u_i ，再采用加权平均法进行解模糊化：

$$u = \frac{\sum_i (\mu(u_i) \times u_i)}{\sum_i \mu(u_i)} \quad (6.21)$$

最后求出模糊补偿控制量，将此量与前面预测控制算法得到的控制量相加即为燃料电池发动机系统的输入控制量。

6.3.4 燃料电池发动机预测控制仿真与分析

利用前面建立的 Elman 神经网络模型进行模拟和仿真。功率给定如图 6.6 所示，电堆电流如图 6.7 所示，电堆电流变化趋势与功率给定情况大致一致。




图 6.6 功率给定




图 6.7 电堆电流

仿真结果如图 6.8~图 6.10 所示。图 6.8 为空压机控制变量变化曲线，该曲线根据基于神经网络的预测控制器计算得出。从图中可看出，控制空压机风量跟随电堆电流的变化采取相应变化，从而满足燃料电池反应的氧气需要。




图 6.8 空压机控制变量变化曲线

图 6.9 是燃料电池电堆输出电压的变化曲线，该曲线是在得到系统的控制变量之后，通过 Elman 神经网络模型计算得到的。

从图中可以看出,当电堆电流阶跃变化时,输出电压也跟着变化;当电流增大时,输出电压减小,这和燃料电池的极化曲线是相符的。在电流突变的瞬间,输出电压也有“毛刺”现象,这是因为电流突变时阴极氧气供给有延时,只要阴极氧气供给恢复到稳定状态,输出电压也会稳定下来。




图 6.9 电堆电压变化曲线

图 6.10 为燃料电池发动机系统仿真功率输出曲线。从该曲线变化情况可以看出,预测控制器能控制功率输出很好地跟随目标给定功率。仿真结果表明,利用基于神经网络的预测控制算法能对燃料电池发动机进行有效控制。




图 6.10 燃料电池发动机系统仿真功率输出曲线

6.4 基于神经网络优化的 PEMFC 多模型切换控制

在工业控制中非线性系统控制的最常见方法是对非线性系统进行线性化，但是对于燃料电池系统这样非线性强、工况多变的复杂系统，采取线性化的方法难以得到准确的控制模型。这时可以采用分段线性化的方法，即在有代表性的工作点附近对系统进行线性化，这样就有了多个模型，然后就可以使用多模型控制或切换系统控制的方法对燃料电池系统进行控制。

切换系统的优化控制问题是控制理论中具有挑战性的领域之一，吸引了控制理论界和工业界的广泛注意。切换系统属于一种特殊的混杂控制系统，它包括一系列的子系统，这些子系统用线性动态方程（微分方程或差分方程）描述。同时它还有一个切换规则，使系统能够自由地在各个子系统间切换。切换系统在工程实践中可以描述很多物理系统和工程系统，如何对其进行控制对学术界是一大挑战，它可以在线性系统理论和高度复杂的系统之间起到很好的桥梁作用。对于切换线性控制系统，其优化控制的目的是找到合适的切换策略来优化性能指标。如果切换信号是给定的，则此切换系统实际上是一个时变控制系统，此时这个问题就可以简化为传统的优化控制问题，用经典的最大值定理或动态规划方法解决。但是切换信号也是一个设计变量，或者由事件驱动（或状态反馈）的切换装置所产生，这时候问题就比较复杂。可以用动态规划的回溯迭代来找到最优解，但是随着优化时间的增加，搜索控制将呈指数增长。为了避免组合爆炸，有的文献^[168]提出了割枝法，尽管该方法可以大大降低搜索时间，但它仍然以指数时间运行。文献^[169]提出将切换系统优化控制问题转化成一个等效问题，然后基于微分几何方法求得的两点边界值得到偏差值，从而得到原问题的解。有的文献^[170]提出一个嵌入的方法，将混合

优化控制问题化解成传统的优化问题,不要求解混合整数规划问题。有的文献^[171~172]提出两种求解切换系统优化控制问题的方法,第一种方法是在两个过程中反复迭代,一个过程得到优化的切换顺序,这一切换顺序确定以后,在另一个过程中得到优化控制的解;另一种方法采用动态规划的方法,将状态空间分成几个子空间进行求解。从以上一些切换系统的优化控制方法来看,这些学者提出了一些新的理论和方法,值得借鉴,这些方法可以减少优化求解时间,但他们所列举的例子一般都比较简单,如果用于复杂的例子,效果如何还未知。

在优化方法中有一种方法是用电路的方法求解优化问题,后来发展成了神经网络优化方法。本章采用这种方法,对燃料电池系统的模型在几个有代表性的工况下分段线性化,得到几个子模型,制订合理的子模型切换策略,然后基于神经网络优化进行燃料电池系统优化控制的研究。

6.4.1 切换系统的优化控制

假设有一 PWA 系统,其状态空间 R 的子空间为 R_i , $i \in I = \{1, 2, \dots, m\}$, 而且子空间满足 $\bigcup_{i=1}^m \bar{R}_i = R$, $R_i \cap R_j = \emptyset$, $i \neq j$, 其中 \bar{R}_i 是 R_i 的闭集。

一个离散 PWA 系统可用状态空间方法进行描述:

$$\begin{aligned} x(k+1) &= A_i x(k) + B_i u(k) \\ y(k) &= C_i x(k) \end{aligned} \quad (6.22)$$

式中, $x \in R^n$ 是状态变量; $u \in R^p$ 是控制输入; $y \in R^q$ 是系统输出; i 是分段切换常数, 从有限索引集 $I = \{1, 2, \dots, m\}$ 中选取。

如果每个子系统的结构已知, 则整个系统的行为取决于切换信号的切换规则。一般来说, 此规则和状态变量或输出变量的前

一状态取值相关：

$$\dot{x}(k+1) = \Psi(x(k), y(k), u(k)) \quad (6.23)$$

一般切换系统优化控制结构图如图 6.11 所示，图 6.11 中各变量和符号意义如下。

Plant——被控对象。

Model 1, Model 2, ..., Model n ——被控对象的 n 个子模型。

Controller 1, Controller 2, ..., Controller n —— n 个子模型切换的 n 个控制器。

Switch——根据切换规则在 n 个控制器间切换。

Selector——基于选择标准在系统的 n 个子模型中选择最适合的子模型。

$y(k)$ ——被控对象的输出。

$u(k)$ ——控制器的输出。

y_r ——系统的参考轨迹或系统的设定值。

$y_m(k)$ ——被选中的子模型的预测输出。

$e(k)$ ——系统的实际输出和模型的预测输出之间的误差。

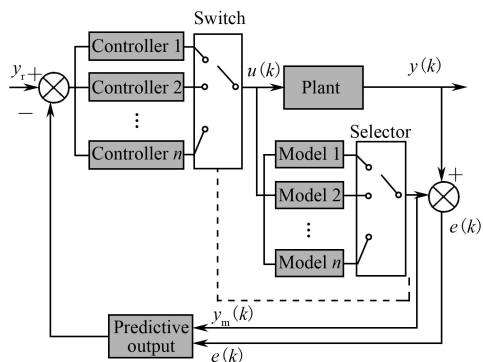


图 6.11 切换系统优化控制结构图

考虑以下受约束有限时间优化控制问题：

$$\min_u J = \sum_{j=1}^N (\mathcal{Y}(k+j) - \mathcal{Y}_r)^T Q (\mathcal{Y}(k+j) - \mathcal{Y}_r) \quad (6.24a)$$

$$+ \sum_{j=0}^{N-1} (u(k+j) - u_r)^T P (u(k+j) - u_r)$$

$$\mathcal{X}(k+1) = A_j \mathcal{X}(k) + B_j u(k) \quad (6.24b)$$

$$\mathcal{Y}(k) = C_j \mathcal{X}(k) \quad (6.24c)$$

$$\dot{\mathcal{X}}(k+1) = \Psi(\mathcal{X}(k), \mathcal{Y}(k), u(k)) \quad (6.24d)$$

$$u_{\min} \leq u(k) \leq u_{\max} \quad j=0, \dots, p-1 \quad (6.24e)$$

式中, N 是预测步数, \mathcal{Y}_r 和 u_r 分别是输出变量和控制变量的参考轨迹, $Q \in R^{q \times q}$ 和 $P \in R^{p \times p}$ 是权重, $\Psi(\mathcal{X}(k), \mathcal{Y}(k), u(k))$ 是切换信号的切换规则。

在这个优化控制问题中, 有 m 个模式, 还有切换规则, 如果直接进行求解比较困难, 为此定义 0-1 变量 $v(k) = [v_1, v_2, \dots, v_m] \in \{0, 1\}$, 将式 (6.24b) 和 (6.24c) 重写为:

$$\mathcal{X}(k+1) = \sum_{i=1}^m A_i \mathcal{X}(k) v_i(k) + \sum_{i=1}^m B_i u(k) v_i(k) \quad (6.25a)$$

$$\mathcal{Y}(k) = \sum_{i=1}^m C_i \mathcal{X}(k) \quad (6.25b)$$

$$\sum_{i=1}^m v_i(k) - 1 = 0 \quad (6.25c)$$

将式 (6.25a)~式 (6.25c) 代入式 (6.24):

$$\min J = f(U, V) = \frac{1}{2} U(k)^T \Gamma U(k) + E^T U(k) + M V(k) \quad (6.26a)$$

$$\dot{\mathcal{X}}(k+1) = \Psi(\mathcal{X}(k), \mathcal{Y}(k), u(k)) \quad (6.26b)$$

$$\sum_{i=1}^m v_i(k) - 1 = 0 \quad (6.26c)$$

$$U_{\min} \leq U(k) \leq U_{\max} \quad (6.26d)$$

其中,

$$U(k)=[u(k) \ u(k+1) \ \cdots \ u(k+N-1)]^T$$

$$V(k)=[v(k) \ v(k+1) \ \cdots \ v(k+N-1)]^T$$

Γ , E 和 M 是常数矩阵。

在每一个采样步求解式 (6.26) 所示的优化问题是一个混合整数二次规划问题, 而求解混合整数二次规划问题是一个 NP 难问题, 在下一节提出用混合神经网络方法求解此问题。

6.4.2 混合神经网络优化

在这一节提出结合连续神经元和离散神经元的混合神经网络来求解切换系统的优化控制问题。混合神经网络由两个相互作用的网络组成: 处理实数值变量的网络 (称为 r -网络) 和处理二进制变量的网络 (称为 b -网络)。神经网络中各变量的赋值空间可表示为

$$\Omega = \prod_{i=1}^L [m_i, M_i] \times \prod_{i=1}^M [0, 1]$$

式中, $L = p \times (N-1)$, $M = m \times (N-1)$ 。

在 r -网络中第 i 个点的输入表示为 h_i^u , 在 b -网络中第 i 个点的输入表示为 h_i^v , 神经网络的动态行为就可以根据这些输入来定义。

假设 $u_i \in [m_i, M_i]$ 和 $v_i \in \{0, 1\}$, 则神经网络的作用函数可定义为:

$$u_i = P_i(h_i^u) = \begin{cases} m_i & h_i^u < m_i \\ h_i^u & m_i \leq h_i^u \leq M_i, \quad i=1, 2, \dots, L \\ M_i & h_i^u > M_i \end{cases} \quad (6.27)$$

$$v_i = \Phi_i(h_i^v) = \begin{cases} 0 & h_i^v < 0 \\ h_i^v & 0 \leq h_i^v \leq 1, \quad i=1, 2, \dots, M \\ 1 & h_i^v > 1 \end{cases} \quad (6.28)$$

混合神经网络的能量函数用惩罚函数的方法构造，惩罚函数增强优化问题的约束条件和切换规则，包括三部分：

$$P(u, v) = G(u, v) + H(u, v) + K(v) \quad (6.29)$$

惩罚函数的第一项用来对等式约束进行惩罚， $G(u, v)$ 取以下形式^[153, 154]：

$$G(u, v) = \left(\sum_{i=1}^M v_i - 1 \right)^2 \quad (6.30)$$

如果优化问题的解 (u, v) 不满足切换规则，则惩罚函数的第二项加一个正惩罚， $H(u, v)$ 采取以下形式：

$$H(u, v) = \begin{cases} 1, & \text{如果解不满足式 (6.26b)} \\ 0, & \text{如果解满足式 (6.26b)} \end{cases} \quad (6.31)$$

最后要求对于所有 $i=1, 2, \dots, m$ 满足 $v_i \in \{0, 1\}$ ，这个约束可用以下惩罚函数来实现：

$$K(v) = \sum_{i=1}^M v_i(1 - v_i) \quad (6.32)$$

如果 $(u, v) \in \Omega$ 是优化问题的一个可行点，所有的约束都满足，即有 $G(u, v) = H(u, v) = V(v) = 0$ ，则最终混合神经网络的能量函数如下：

$$E(u, v) = Af(u, v) + B \left(\sum_{i=1}^M v_i - 1 \right)^2 + CH(u, v) + D \sum_{k=1}^M v_k(1 - v_k) \quad (6.33)$$

式中， A 、 B 、 C 和 D 是惩罚系数。

混合神经网络的动态可以用能量函数的梯度来描述，即：

$$\dot{h}_i^u = -\eta_u \frac{\partial E}{\partial u_i} = -\eta_u A \frac{\partial f}{\partial u_i} \quad (6.34)$$

$$u_i = P_i(h_i^u) \quad i=1, \dots, L \quad (6.35)$$

$$\begin{aligned}\dot{h}_i^v &= -\eta_v \frac{\partial E}{\partial u_i} \\ &= -\eta_v \left[A \frac{\partial f}{\partial v_i} + 2B \left(\sum_{j=1}^m v_j - 1 \right) + CH + D(1 - 2v_i) \right] \quad (6.36)\end{aligned}$$

$$u_i = \Phi_i(h_i^v) \quad i=1, \dots, M \quad (6.37)$$

式中, η_u 和 η_v 是正常数, 用来刻画混合神经网络动态行为。

下面来证明以上构造的混合神经网络的动态行为可以使能量函数单调下降, 首先考虑由于连续神经元和离散神经元的输出变化造成的能量函数的变化率:

$$\begin{aligned}\frac{dE}{dt} &= \sum_{i=1}^L \frac{\partial E}{\partial u_i} \dot{u}_i + \sum_{i=1}^M \frac{\partial E}{\partial v_i} \dot{v}_i \\ &= -\sum_{i=1}^L \eta_u (\dot{h}_i^u)^2 P_i(h_i^u) - \sum_{i=1}^M \eta_v (\dot{h}_i^v)^2 \Phi_i(h_i^v) \leq 0\end{aligned} \quad (6.38)$$

因此能量函数 E 是混合神经网络的李亚普诺夫函数, 单调下降, 直到达到能量函数 E 的局部最小值。这种新的混合神经网络方法和传统的数学规划相比, 更容易并行实现。

6.4.3 仿真结果

首先根据第 2 章建立的燃料电池系统模型和第 3 章开发的燃料电池模拟仿真软件, 建立燃料电池系统的切换模型。利用第 3 章中的 Simulink 模型将燃料电池系统在电堆电流为 100A, 200A 和 300A 时进行线性化, 可得到 3 个线性化子模型, 则有:

$$\begin{aligned}x(k+1) &= A_j x(k) + B_j u(k) \\ y(k) &= C_j x(k)\end{aligned}$$

其中, 状态变量为供应管腔空气质量、阴极氧气质量、阴极氮气质量、阴极水质量、阳极水质量和回流管腔空气质量, 即 $x = [m_{sm}, m_{O_2}, m_{N_2}, m_{w,ca}, m_{w,an}, m_{tm}]$, 控制变量为进堆空气流量和加

湿水流量, 即 $u = [W_{cp}, W_{inj}]$, 系统的输出为氧气流量和阴极水质
量, 3 个子模型的系数 A_i , B_i , C_i 分别为:

$$\begin{aligned}
 A_1 &= \begin{bmatrix} -427.48 & 904.1 & 1032.9 & 1606 & 0 & 0 \\ 0 & -15.76 & -5.98 & -10.48 & 0 & 7.83 \\ 0 & -17.66 & -32.02 & -37.19 & 0 & 27.78 \\ 0 & -2.75 & -3.31 & -267.96 & 492.77 & 4.33 \\ 0 & 0 & 0 & 246.38 & -492.77 & 0 \\ 0 & 36.161 & 41.32 & 64.24 & 0 & -79.87 \end{bmatrix} \\
 B_1 &= \begin{bmatrix} 1 & 0 \\ 0.218 & 0 \\ 0.716 & 0 \\ 0.066 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \\
 A_2 &= \begin{bmatrix} -427.48 & 904.1 & 1032.9 & 1606 & 0 & 0 \\ 0 & -21.33 & -7.16 & -12.82 & 0 & 9.87 \\ 0 & -21.12 & -41.13 & -46.02 & 0 & 35.42 \\ 0 & -2.76 & -3.36 & -267.85 & 492.77 & 4.63 \\ 0 & 0 & 0 & 246.38 & -492.77 & 0 \\ 0 & 45.21 & 51.64 & 80.3 & 0 & -99.84 \end{bmatrix} \\
 B_2 &= \begin{bmatrix} 1 & 0 \\ 0.218 & 0 \\ 0.716 & 0 \\ 0.066 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \\
 A_3 &= \begin{bmatrix} -427.48 & 904.1 & 1032.9 & 1606 & 0 & 0 \\ 0 & -29.86 & -10.02 & -17.95 & 0 & 13.81 \\ 0 & -29.56 & -57.58 & -64.425 & 0 & 49.589 \\ 0 & -3.87 & -4.7 & -276.43 & 492.77 & 6.49 \\ 0 & 0 & 0 & 246.38 & -492.77 & 0 \\ 0 & 63.29 & 72.3 & 112.42 & 0 & -139.78 \end{bmatrix} \\
 B_3 &= \begin{bmatrix} 1 & 0 \\ 0.218 & 0 \\ 0.716 & 0 \\ 0.066 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \\
 C_1 = C_2 = C_3 &= \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}
 \end{aligned}$$

子模型间的切换规则为:

$$J_i(t) = \alpha e_i^2(t) + \beta \int_0^t e^{-\lambda(t-\tau)} e_i^2(\tau) d\tau$$

$$\alpha \geq 0, \beta, \lambda > 0$$

式中, α 和 β 是系数, λ 是遗忘因子, 通过反复比较, 它们的取值分别为: $\alpha=1$, $\beta=1.3$, $\lambda=0.65$ 。

应用本章提出的基于混合神经网络的切换系统优化控制方法, 对燃料电池系统进行控制。控制的目标有 3 个, 一是要使输出电压尽可能地高, 二是要保持氧气过量系数在 2 左右, 三是要保持电堆的阴极湿度在 0.95 左右。根据第 3 章的动态分析结果可知, 如果要输出电压尽可能高, 需要足够的氧气、氢气、合适的温度及合适的湿度。在氢气流量固定和温度固定的情况下, 只要将氧气量和湿度控制好, 就可以得到尽可能高的输出电压。根据第 2 章的计算公式, 可以将氧气过量系数和阴极湿度转化为阴极空气质量和阴极水质量, 燃料电池优化控制的目标函数为:

$$\min_u J = \sum_{j=1}^N (y(k+j) - y_r)^T Q (y(k+j) - y_r)$$

$$+ \sum_{j=0}^{N-1} (u(k+j) - u_r)^T P (u(k+j) - u_r)$$

式中, y 为系统的输出, u 为控制变量, 权系数取为 $Q = \begin{bmatrix} 1 & 0 \\ 0 & 10 \end{bmatrix}$,

$P = \begin{bmatrix} 1 & 0 \\ 0 & 500 \end{bmatrix}$, 预测步数 $N=3$, 将目标函数和相关系数代入优化问题式 (6.26) 中, 然后用混合神经网络的方法进行处理。

在燃料电池系统中采样时间为 0.1 秒, 在每一采样步混合神经网络状态变量的变化轨迹如图 6.12 所示。从图 6.12 可以看出, 混合神经网络的状态变量 x 可以在 0.05 秒内收敛, 比采样时间短, 可以满足实时控制的需要。




图 6.12 混合神经网络状态变量的变化轨迹

下面采用基于混合神经网络的优化方法对燃料电池系统进行优化控制仿真，燃料电池系统的电流变化如图 6.13 所示。从图 6.13 可以看出，在 50 秒内，燃料电池系统的电流先快速上升，达到 300A 后，持续 15 秒，又快速下降。在这样的负载变化情况下，采用基于混合神经网络优化的燃料电池系统控制的仿真结果如图 6.14~图 6.18 所示。




图 6.13 燃料电池系统的电流变化

图 6.14 是氧气过量系数变化曲线。该图是在得到阴极氧气质量之后，除以在一定电流条件下电堆反应所需氧气量得到的。从图 6.14 可以看出，氧气过量系数可以保持在 2 左右，中间有几个向上或向下的“毛刺”，这是因为在电流突变的瞬间，阴极入口空气流量有 0.1 秒左右的延时，从而导致瞬间的氧气过量系数会大于 2 或小于 2，但时间短且下降的幅度不大，没有小于 1.5，不会产生氧气供应量不够的情况。




图 6.14 氧气过量系数变化曲线

图 6.15 是阴极湿度变化曲线。该图是在得到阴极水质量之后，除以阴极蒸汽饱和时的质量得到的。从图 6.15 可以看出，阴极的湿度保持在 0.95 左右，只是在电流突变的地方有变化，这是因为在电流突变的瞬间，加湿量的变化有延时，从而导致瞬间的阴极湿度会大于或小于 0.95，但湿度保持在 0.9~1 之间，对电堆的输出电压影响不大。

图 6.16 是燃料电池输出电压变化曲线。在得到系统的输出(阴极入口空气流量和阴极加湿水流量)之后，通过第 3 章的 Simulink 模型可以得到燃料电池的输出电压。从图 6.16 可以看出，当电堆

电流阶跃变化时，输出电压也跟着变化，当电流增大时，输出电压减小，这和燃料电池的极化曲线是相符的。在电流突变的瞬间输出电压也有“毛刺”现象，这是因为电流突变时阴极氧气过量系数和阴极湿度有延时，只要阴极氧气过量系数和阴极湿度恢复到稳定状态，输出电压也会稳定下来。




图 6.15 阴极湿度变化曲线




图 6.16 燃料电池输出电压变化曲线

图 6.17 是控制变量—阴极入口空气风量变化曲线，该曲线是根据基于神经网络的燃料电池优化控制计算出来的。从图 6.17 可以看出，阴极入口空气风量可以跟随电堆电流的变化而相应变化，从而满足燃料电池反应的氧气需要。图 6.18 是控制变量—阴极加湿水流量变化曲线，该曲线也是根据基于神经网络的燃料电池优化控制计算出来的。从图 6.18 可以看出，阴极加湿水流量可以跟随电堆电流的变化而相应变化，使阴极的湿度保持在 0.95 左右，而且在电堆电流为 300A 时加湿水流量为零，这说明在此时电堆生成的水已经很多，不再需要外部加湿。

从仿真结果图 6.14~图 6.18 可以看出，本章提出的控制方法可以满足燃料电池系统的需要，使燃料电池系统的氧气过量系数保持在 2 左右，燃料电池阴极湿度保持在 0.95 左右，输出电压能够跟随负载变化且能快速达到该负载下的最大值。




图 6.17 控制变量—阴极入口空气风量变化曲线




图 6.18 控制变量—阴极加湿水流量变化曲线

6.4.4 小结

本章针对燃料电池这一多输入/多输出、耦合性强的复杂系统，采用分段线性化的方法将其转化成线性切换系统的优化控制问题，提出混合神经网络方法对混合整数规划问题进行求解。将提出的控制方法应用到燃料电池系统中，使燃料电池系统的氧气过量系数和阴极湿度保持在合适的值，输出电压能够跟随负载变化且能快速达到该负载下的最大值，仿真结果证明了本章提出的方法的有效性和实时性。

参 考 文 献

- [1] D M Bernardi, M W Verbrugge. Mathematical model of a gas diffusion electrode bonded to a polymer electrolyte [J]. AIChE Journal 1991, 37(8): 1151-1163.
- [2] T E Springer, M S Wilson, S Gottesfeld. Modeling and experimental diagnostics in polymer electrolyte fuel cells [J]. Journal of Electrochemical Society, 1993, 140(12): 3513-3526.
- [3] A Rowe, X G Li. Mathematical modeling of proton exchange membrane fuel cells [J]. Journal of Power Sources, 2001, 102(1-2): 82-96.
- [4] F Barbir. Trade off design analysis of operating pressures and temperatures in PEM fuel cell systems [A]. Proceedings of the ASME Advanced Energy Systems [C], 1999: 305-315.
- [5] H K Geyer, R K Ahluwalia. GC tool for fuel cell system design and analysis: user documentation [J]. Argonne National Labs, Report No. ANL-98/9, 1998.
- [6] 胡卫华, 谢起成, 田光宇, 等. 质子交换膜燃料电池电压模型研究 [J]. 汽车技术, 2002(10): 8-11.
- [7] J C Amphlett, R M Baumert, R F Mann, et al. Performance modeling of the Ballard Mark IV solid polymer electrolyte fuel cell [J]. Journal of the Electrochemical Society, 1995, 142: 1-15.
- [8] R F Mann, J C Amphlett, M A Hooper, et al. Development and application of a generalized steady-state

- electrochemical model for a PEM fuel cell [J]. Journal of Power Sources, 2000, 86: 173-180.
- [9] S Jemei, D Hissel, M C Pera, et al. On-board fuel cell power supply modeling on the basis of neural network methodology [J]. Journal of power sources, 2003(124): 479-486.
- [10] S Gelfi, A G Stefanpoulou, J T Pukrushpan, et al. Dynamics of low-Pressure and high-Pressure fuel cell air supply system [A]. Proceedings of the American Control Conference [C], 2003, v3: 2049-2054.
- [11] J T Pukrushpan, H Peng, A G Stefanpoulou. Simulation and analysis of transient fuel cell system performance based on a dynamic reactant flow model [A]. In: ASME, eds. Proceedings of ASME international mechanical engineering congress & exposition [C], NEW Orleans, Louisiana: ASME, 2002: 1-12.
- [12] F L Chen, H S Chu, C Y Soong, et al. Effective scheme to control the dynamic behavior of the water transport in the membrane of PEM fuel cell [J]. Journal of Power Sources, 2005, 140(2): 243-249.
- [13] J T Pukrushpan, A G Stefanopoulou, H Peng. Control of fuel cell power systems: Principles, model, analysis and feedback design [M]. Springer-Verlag London, 2004.
- [14] 丁刚强, 罗志平, 潘牧, 等. 质子交换膜燃料电池组水管理研究 [J]. 能源技术, 2005, 26(1): 18-22.
- [15] W M Yan, F L Chen, H Y Wu, et al. Analysis of thermal and water management with temperature-dependent diffusion effects in membrane of proton exchange membrane fuel cells [J]. Journal of Power Sources, 2004, 129(2): 127-137.
- [16] 马天才, 孙泽昌, 许思传. 质子交换膜燃料电池温度控制仿真模型 [J]. 系统仿真学报, 2005, 17(3): 548-551.

- [17] Y J Zhang, M G Ouyang, et al. A model predicting performance of proton exchange membrane fuel cell stack thermal systems [J]. Applied thermal engineering, 2004, 24(4): 501-513.
- [18] J S Yi, T V Nguyen. An along-the channel model for proton exchange membrane fuel cells [J]. Journal of the Electrochemical Society, 1998, 145(4): 1149-1159.
- [19] R N Methekar, V Prasad, R D Gudi. Dynamic analysis and linear control strategies for proton exchange membrane fuel cell using a distributed parameter model [J]. Journal of Power Sources, 2007, 165(1): 152 - 170.
- [20] P R Pathapti, X Xue, J. Tang. A new dynamic model for predicting transient phenomena in a PEM fuel cell system [J]. Renewable Energy, 2005(30): 1-22.
- [21] X Xue, J A Tang, et al. System level lumped-parameter dynamic modeling of PEM fuel cell [J]. Journal of Power Sources, 2004, 133(2): 188-204.
- [22] M Wohr, K Bolwin, et al. Dynamic modeling and simulation of a polymer membrane fuel cell including mass transport limitation [J]. International Journal of Hydrogen Energy, 1998, 23(3): 213-218.
- [23] Y H Hung, P H Lin, C H Wu, et al. Real-time dynamic modeling of hydrogen PEMFCs[J]. Journal of the Franklin Institute, 2008, 345: 182-203.
- [24] C Kunusch, A Husar, P F Puleston, et al. Linear identification and control model adjustment of a PEM fuel cell stack [J]. International Journal of Hydrogen Energy, 2008, 33: 3581-3587.
- [25] S O T Ogaji, R Singh, P Pilidis, et al. Modelling fuel cell performance using artificial intelligence [J]. Journal of Power Sources, 2006, 154(1): 192-197.

- [26] A Saengrungs, A Abtahi, A Zilouchian. Neural network model for a commercial PEM fuel cell system [J]. Journal of Power Sources, 2007, 172(2): 749-759.
- [27] C H Li, X J Zhu, G Y Cao, et al. Identification of the Hammerstein model of a PEMFC stack based on least squares support vector machines [J]. Journal of Power Sources, 2008, 175(1): 303-316.
- [28] Vicky Rouss, Willy Charon. Multi-input and multi-output neural model of the mechanical nonlinear behaviour of a PEM fuel cell system [J]. Journal of Power Sources, 2008, 175(1): 1-17.
- [29] K Haraldsson, K Wipke. Evaluating PEM fuel cell system models [J]. Journal of Power Sources, 2004, 126(1-2): 88-97.
- [30] Emmeskay Documentation. www.emmeskay.com.
- [31] S Gurski. Cold start effects on performance and efficiency for vehicle fuel cell system. MScThesis, Virginia Polytechnic Institute and State University, 2002.
- [32] G Kulp, D Nelson. in: Proceedings of the SAE, 2001-FTT-63 (2001).
- [33] K Johansson (Haraldsson). Modelling of a proton exchange membrane fuel cell system for automotive applications. Licentiate of Engineering Thesis, Royal Institute of Technology, Stockholm, Sweden, 2001.
- [34] T E Springer, T A Zawodzinski, S Gottesfeld. Polymer electrolyte fuel cell model [J]. Journal of Electrochemical Society, 1991, 138(8): 2334-2342.
- [35] X C Yu, B Zhou, A Sobiesiak. Water and thermal management for Ballard PEM fuel cell stack [J]. Journal of Power Sources, 2005, 147(1-2): 184-195.
- [36] R Sonntag, C Borgnakke, G Van Wylen. Fundamentals of Thermodynamics [M]. New York: Wiley, 1998.

- [37] T Nguyen, R White. A water and heat management model for proton exchange membrane fuel cells [J]. Journal of Electrochemical Society, 1993, 140(8): 2178-2186.
- [38] Dutta S, Shimpalee S, Van Zee J. Numerical prediction of mass-exchange between cathode and anode channels in a PEM fuel cell[J]. International Journal of Heat and Mass Transfer, 2001, (44): 2029-2042.
- [39] Okada, Tatsuhiro. Theory for water management in membranes for polymer electrolyte fuel cells [J]. Journal of Electroanalytical Chemistry, 1999, (465): 1-17.
- [40] 黄倬, 屠海令, 张冀强. 质子交换膜燃料电池的研究开发与应用[M]. 北京: 冶金工业出版社, 2000.
- [41] P F Baldi, K Homik. Learning in Linear Neural Networks: A Survey [J]. IEEE Trans. On Neural Networks, 1995, 6(4): 837-857.
- [42] 高隽. 人工神经网络原理及仿真实例[M]. 北京: 机械工业出版社, 2003.
- [43] 夏文华, 邓飞其, 罗毅平. 具周期输入的有限连续分布时滞神经网络周期解的全局指数稳定性[J]. 数学物理学报, 2008 (01): 170-178.
- [44] 周小兵. 时滞神经网络的动力学研究[D]. 成都: 电子科技大学, 2008.
- [45] 陈艳艳, 朱跃华, 王振报, 等. 基于 MATLAB 神经网络工具箱的公交出行比例预测[J]. 北京工业大学学报, 2008 (02): 173-177.
- [46] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真程序设计[M]. 北京: 清华大学出版社, 2005.
- [47] 南晋华. 决策神经网络模型及应用研究[D]. 武汉: 华中科技大学, 2008.
- [48] 张良均. 神经网络实用教程[M]. 北京: 机械工业出版社, 2008.

- [49] 飞思科技产品研发中心. 神经网络理论与 MATLAB7 实现——MATLAB 应用技术[M]. 北京: 电子工业出版社, 2005.
- [50] Khanna T Foundations of neural networks [M]. Boston: Addison-Wesely Publishing Company, 1990.
- [51] 张军英, 保铮. 前向网络隐层节点数的最小上界研究[A]. 1997 年中国神经计算科学大会论文集[C]. 北京: 人民邮电出版社, 1997: 177-184.
- [52] 张立明. 人工神经网络的模型及应用[M]. 上海: 复旦大学出版社, 1993.
- [53] 张立炎, 潘牧, 全书海. 燃料电池空气供应系统建模与动态仿真的研究[J]. 系统仿真学报, 2008, 20(4): 850-854.
- [54] 张立炎, 潘牧, 全书海. PEMFC 水管理的动态分析及仿真[J]. 电池, 2008, 38(1): 17-20.
- [55] 杨武. 车用燃料电池动力系统的仿真研究[D]. 北京: 清华大学, 2004.
- [56] 杨武, 裴普成, 武洁云, 等. 燃料电池发动机空气系统特性的仿真[J]. 清华大学学报(自然科学版), 2004, 44(5): 703-707.
- [57] 肖合林, 候献军, 颜伏伍. 燃料电池发动机系统计算分析[J]. 武汉理工大学学报, 2004, 26(5): 64-67.
- [58] Akira Taniguchi, Tomoki Akita, Kazuaki Yasuda, et al. Analysis of degradation in PEMFC caused by cell reversal during air starvation[J]. International Journal of Hydrogen Energy, 2008, 33(9): 2324-2329.
- [59] J T Pukrushpan, A G Stefanopoulou, H Peng. Control of Fuel Cell Breathing: Initial Results on the Oxygen Starvation Problem [J]. IEEE Control Systems Magazine, 2004, 4(2): 30-46.
- [60] M Fournier, J Hamelin, K Agbossou, et al. Fuel cell Operation with Oxygen Enrichment[J]. Fuel Cells, 2002, 2(2): 117-122.

- [61] 秦敬玉, 毛宗强, 徐景明, 等. 过量空气系数对燃料电池发动机输出特性的影响[J]. 汽车工程, 2004, 26(4): 374-381.
- [62] 孙红, 吴玉厚. 反应气体流量和背压对 PEM 燃料电池性能的影响[J]. 沈阳建筑大学学报(自然科学版), 2006, 22(6): 1033-1037.
- [63] 简弃非, 赵永利, 刘海燕. 质子交换膜燃料电池运行参数的仿真优化[J]. 华南理工大学学报(自然科学版), 2006, 34(10): 6-10.
- [64] 王金龙, 王登峰, 陈静, 等. 影响车用质子交换膜燃料电池性能的诸因素分析及试验[J]. 北京交通大学学报, 2007, 31(6): 23-25.
- [65] 张连洪, 揭伟平, 谢春刚, 等. 温度、压力和湿度对 PEMFC 堆电效率的影响[J]. 天津大学学报, 2007, 40(5): 593-598.
- [66] 赵奕磊, 毛宗强, 奚树人, 等. 5kW 氢空 PEMFC 的性能[J]. 电池, 2005, 35(1): 6-7.
- [67] D T Santa Rosa, D G Pinto, V S Silva, et al. High performance PEMFC stack with open cathode at ambient pressure and temperature conditions[J]. International Journal of Hydrogen Energy, 2007, 32(17): 4350-4357.
- [68] Seong Uk Jeong, Eun Ae Cho, Hyoung-Jhun Kim, et.al. Effects of cathode open area and relative humidity on the performance of air-breathing polymer electrolyte membrane fuel cells [J]. Journal of Power Sources, 2006, 158(1): 348-353.
- [69] 许思传, 程钦, 马天才. 燃料电池发动机空气参数的最优控制[J]. 车用发动机, 2006, 4(2): 24-28.
- [70] 谢晋, 黄允千. 温度、湿度对质子交换膜燃料电池的影响[J]. 上海海事大学学报, 2005, 26(3): 60-63.
- [71] J J Baschuk, X Li Modeling of polymer electrolyte membrane fuel cells with variable degrees of water

- flooding[J]. Journal of Power Sources, 2000, 86(2): 184-191.
- [72] D M Chen, H Peng. Modeling and Simulation of a PEM Fuel Cell Humidification System[C]. Proceeding of the 2004 American Control Conference, 2004: 823-827.
- [73] J H Jang. A Simple Model Predicting Transient Thermal Management of PEMFC and Cooling System[C]. The 1st International Forum On Strategic Technology, 2006: 394-402.
- [74] T A Jr Zawodzinski, T E Springer, et al. Comparative Study of Water Uptake by and Transport through Fuel Cell Membranes[J]. Journal of the Electrochemical Society, 1993, 140(7): 1981-1985.
- [75] Mustapha Najjari, Faycel Khemili, Sassi Ben Nasrallah. The effects of the cathode flooding on the transient responses of a PEM fuel cell[J]. Renewable Energy, 2008, 33(8): 1824-1831.
- [76] H Sun, L J Guo, H T Liu. The Effect of Operating Parameters on Water Transport in PEM Fuel Cells[J]. Heat Transfer Asian Research, 2006, 35(2): 84-100.
- [77] L X Hao, H M Yu, J B Hou, et al. Transient behavior of water generation in a proton exchange membrane fuel cell[J]. Journal of Power Sources, 2008, 177(2): 403-411.
- [78] Y M Ferng, et al. Numerical simulation of thermal-hydraulic characteristics in a proton exchange membrane fuel cell[J]. International Journal of Energy Research, 2003, 27(5): 493-511.
- [79] Jong-Woo Ahn, Song-Yul Choe. Coolant controls of a PEM fuel cell system[J]. Journal of Power Sources, 2008, 179(1): 253-264.
- [80] Phatiphat Thounthong, Stephane Rael, Bernard Davat. Control Algorithm of Fuel Cell and Batteries for

- Distributed Generation System[J]. IEEE Transactions on Energy Conversion, 2008, 23(1):148-155.
- [81] C Wang, M H Nehrir, H Gao. Control of PEM Fuel Cell Distributed Generation Systems[J]. IEEE Transactions on Energy Conversion, 2006, 21(2): 584-59.
- [82] A Azmy, I Erlich. Online optimal mangement of PEM fuel cells using neural networks[J]. IEEE Transactions on Power Delivery, 2005, 20(21): 1051-1058.
- [83] H Abtahi, Z Ali, A Saengrung. Water management of PEM fuel cells using fuzzy logic controller system[C]. IEEE International Conference on System Man and Cybematics, 2005: 3486-3490.
- [84] Y F Xiong, X R Deng. Research on the Control of the Cathode Gas Flow and Pressure of A Small PEM Fuel Cell[C]. Proceedings of the 6th World Congress on Intelligent Control and Automation, 2006: 7711-7715.
- [85] W B Gao, J C Hung. Variable structure control of nonlinear systems: a new approach [J]. Indus trial Electronics, IEEE Transactions on, 1993, 40(1): 43-55.
- [86] F C Wang, H T Chen, et al. Multivariable robust control of a proton exchange membrane fuel cell system[J]. Journal of Power Sources, 2008, 177(2) : 393-403.
- [87] J O Schumacher, P Gemmar, M Denne, et al. Control of miniature proton exchange membrane fuel cells based on fuzzy logic[J]. Journal of Power Sources, 2004, 129: 144-151.
- [88] L C Iwan, R F Stengel. The application of neural networks to fuel processors for fuel-cell vehicles[J]. IEEE Transactions on Vehicular Technology, 2001, 50: 124-143.
- [89] A P E Almeida, G Smoesm. Neural optimal conrrol of PEM fuel cells with parrameltric CMIAC networks[J]. IEEE

- Transactions on Industry Applications, 2005, 41(1): 237-245.
- [90] S Dutta, S Shimpalee, et al. Numerical prediction of mass-exchange between cathode and anode channels in a PEM fuel cell[J]. International Journal of Heat and Mass Transfer, 2001, 44(11): 2024-2042.
- [91] H Chan, A Rad. Real-time flow control using neural networks [J]. ISA Transactions, 2000, 39(1): 93-101.
- [92] Y H Kim, S S Kim. An electrical modeling and fuzzy logic control of a fuel cell generation system[J]. IEEE Transactions on Energy Conversion, 1999, 14(2): 234-244.
- [93] Y D Zhan, J G Zhu, Y G Guo, et al. Control of Proton Exchange Membrane Fuel Cell Based on Fuzzy Logic[C]. Proceedings of the 26th Chinese Control Conference, 2007: 343-349.
- [94] C K Long, S S Xie, Y Wu. Research and experiment of pneumatic servo system based on neural network PID control[C]. Proceedings of the 6th World Congress on Intelligent Control and Automation, 2006: 6683-6689.
- [95] Y P Yang, Z W Liu, et al. Model Reference Adaptive Control of a Low Power Proton Exchange Membrane Fuel Cell[C]. Proceedings of the 46th IEEE Conference on Decision and Control, 2007: 1314-1319.
- [96] Y G Niu, Y Zou, C W Yang. Neural network based adaptive tracking control for a class of nonlinear systems[J]. Control Theory and Applications, 2001, 18(6): 461-464.
- [97] Z J Mo, X J Zhu, L Y We, et al. Parameter optimization for a PEMFC model with hybrid genetic algorithm[J]. International Journal of Energy Research, 2006, 30(8): 583-597.
- [98] Z J Mo, X J Zhu, G Y Cao. Design and Simulation of Fuzzy Controller for PEMFCs[C]. Proceedings of the IEEE

- International Conference on Industrial Technology, 2005: 220-224.
- [99] Y D Tian, X J Zhu, G Y Cao. An Adaptive Fuzzy Control Strategy of Movable Power Sources of Proton Exchange Membrane Fuel Cells[C]. 2005 International Conference on Communications, Circuits and Systems, 2005, 2: 1007-1011.
- [100] 田玉冬, 朱新坚, 曹广益. 质子交换膜燃料电池的建模与控制[J]. 电池, 2004, 34 (4): 301-303.
- [101] 田玉冬, 朱新坚, 等. 质子交换膜燃料电池移动电源温度模糊控制[J]. 电源技术, 2005, 29(3): 157-159.
- [102] 邵庆龙, 曹广益, 等. 质子交换膜燃料电池电堆温度的非线性控制[J]. 系统仿真学报, 2004, 16(11): 2583-2586.
- [103] 李曦, 朱新坚, 曹广益, 等. 基于模糊建模技术的 PEMFC 非线性控制[J]. 电源技术, 2005, 29(4): 243-249.
- [104] 李曦, 曹广益, 等. PEMFC 的模糊辨识和非线性预测控制[J]. 计算机仿真, 2005, 22(2): 178-181.
- [105] 向金凤, 全书海. 车用 25kW 燃料电池冷却水系统 Fuzzy-PID 控制器的研究[J]. 华中师范大学学报(自然科学版), 2004, 38(2): 174-182.
- [106] 全书海, 王超, 宋娟. 车用燃料电池发动机控制系统与协调控制研究[J]. 华中师范大学学报(自然科学版), 2005, 39(3): 323-328.
- [107] 阮诗峰, 全书海, 陈启宏. 可软配置燃料电池发动机控制系统研究[J]. 微计算机信息, 2008, 24(31): 64-71.
- [108] 卫国爱. 车用 PEMFC 空气供给系统建模及控制策略研究[D]. 武汉: 武汉理工大学, 2010.
- [109] 刘晨晖. 多变量过程控制系统解耦理论[M]. 北京: 水利电力出版社, 1984: 1-3.
- [110] 金以慧. 过程控制[M]. 北京: 清华大学出版社, 1993: 150-179.

- [111] E H Bristol. On a New Measure of Interaction for Multivariable Process Control [J]. IEEE. Trans. Automatic Control, 1966, AC-11(1): 133-134.
- [112] 何玉彬, 李新忠. 神经网络控制技术及其应用[M]. 北京: 科学出版社, 2000: 44.
- [113] 徐丽娜. 神经网络控制[M]. 北京: 电子工业出版社, 2003: 124, 144.
- [114] 陶永华, 尹怡新, 葛芦生. 新型 PID 控制及其应用[M]. 北京: 机械工业出版社, 1999: 158-170.
- [115] 刘金琨. 先进 PID 控制及其 MATLAB 仿真[M]. 北京: 电子工业出版社, 2003: 93-116, 153-163.
- [116] 何衍庆, 姜捷, 江艳君, 等. 控制系统分析、设计和应用[M]. 北京: 化学工业出版社, 2003: 269-278.
- [117] Sampath Yerramalla, Asad Davari, Ali Feliachi, et al. Modeling and simulation of the dynamic behavior of a polymer electrolyte membrane fuel cell[J]. Journal of Power Sources, 2003, (124): 104-113.
- [118] H Gorgun, M Arcak, F Barbir. A voltage-based observer design for membrane water content in PEM fuel cells [J]. American Control Conference, 2005: 4796-4801.
- [119] D Chu, R Z Jiang. Performance of polymer electrolyte membrane fuel cell (PEMFC) stacks [J]. Journal of Power Sources, 1999, 83(1-2): 128-133.
- [120] S Shimpalee, D Spuckler, J W Van Zee. Prediction of transient response for a 25-cm² PEM fuel cell [J]. Journal of Power Sources, 2007, 167(1): 130-138.
- [121] M Alessandro, D D Alfonso, Y G Guezennec, et al. Control-oriented model for an automotive PEM fuel cell system with imbedded 1+1D membrane water transport [c]. IEEE Vehicle Power and Propulsion Conference, 2005: 611-618.
- [122] F Wolfgang, R Stephane, D Bernard. Mathematical model and characterization of the transient behavior of a PEM

- fuel cell [J]. IEEE Transaction on Power Electrons, 2004, 19(5): 1234-1241.
- [123] H Gorgun, M Arcak, F Barbir. An algorithm for estimation of membrane water content in PEM fuel cells [J]. Journal of Power Sources, 2006, 157(1): 389-394.
- [124] V N Trung, M W Knobbe. A liquid water management strategy for PEM fuel cell stacks [J]. Journal of Power Sources, 2003, 114(1): 70-79.
- [125] D M Chen, H Peng Modeling and simulation of a PEM fuel cell humidification system [c]. Proceeding of the 2004 American Control conference, 2004: 822-827.
- [126] H Abtahi, Z Ali, A Saengrung. Water management of PEM fuel cells using fuzzy logic controller system [A]. Systems, Man and Cybernetics, IEEE International Conference on [C]. 2005, (4): 3486-3490.
- [127] A Zheng, W Zhang. Nonlinear predictive control, chapter Computationally Efficient Nonlinear Model Predictive Control Algorithm for Control of Constrained Nonlinear Systems. IEE Control Engineering Series, 2001.
- [128] A Bemporad, M Morari, et al. The explicit linear quadratic regulator for constrained systems [J]. Automatica, 2002, 38(1): 3-20.
- [129] R A Bartlett, A Wachter, L T Biegler. Active set vs. interior point strategies for model predictive control [c]. In Proceedings of America Control Conference, 2000.
- [130] C V Rao, S J Wright, J B Rawlings. Application of interior-point methods to model predictive control[J]. Journal of Optimization Theory and Applications, 1998, 99: 723-757.
- [131] A G Wills, W P Heath. Interior-point algorithms for nonlinear model predictive control. In proceedings of

- assessment and future directions of nonlinear model predictive control, Springer, 2007.
- [132] H G Bock, M M Diehl, et al. Nonlinear model predictive control, chapter a direct multiple shooting method for real-time optimization of nonlinear DAE processes. Birkhauser, 2000.
- [133] P O M Scokaert, D Q Mayne, J B Rawlings. Suboptimal model predictive control (feasibility implies stability) [J]. IEEE Transactions on Automatic Control, 1999, 44(3): 648-654.
- [134] 李德伟, 席裕庚, 秦辉. 预测控制等效集结优化策略的研究 [J]. 自动化学报, 2007, 33(3): 302-308.
- [135] D W Tank, J J Hopfield. Simple neural optimization networks: An A/D converter, signal decision circuit, and a linear programming, IEEE Trans. Circuits Syst, 1986, Vol. CAS-33, no.5: 533-541.
- [136] M P Kennedy, L O Chua. Neural networks for nonlinear programming [J]. IEEE Trans. Circuits Syst, 1988, 35(5): 554-562.
- [137] A Rodriguez-Vazquez, R Domínguez-Castro, A Rueda, et al. Nonlinear switched-capacitor neural networks for optimization problems [J]. IEEE Trans. Circuits Syst, 1990, 37: 384-397.
- [138] Y S Xia. A new neural network for solving linear and quadratic programming problems [J]. IEEE Trans. Neural Netw, 1966, 7(6): 1544-1547.
- [139] Y S Xia, J Wang. A general methodology for designing globally convergent optimization neural networks [J]. IEEE Trans. Neural Netw, 1998, 9(6): 1331-1343.
- [140] Q Tao, J D Cao, M S Xue, et al. A high performance neural network for solving nonlinear programming problems with hybrid constraints [J]. Phys. Lett. A, 2001, 288(2): 88-94.

- [141] J Wang, Q Hu, D Jiang. A Lagrangian neural network for kinematic control of redundant robot manipulators [J]. IEEE Trans. Neural Netw, 1999, 10(5): 1123-1132.
- [142] Y S Xia, J Wang. A recurrent neural network for solving nonlinear convex programs subject to linear constraints [J]. IEEE Transactions on Neural Networks, 2005, 16(2): 379-386.
- [143] Y S Xia, J Wang. A one-layer recurrent neural network for support vector machine learning [J]. IEEE Trans. Syst, Man, Cybern. B, Cybern, 2004, 34(2): 1261-1269.
- [144] P B Watta, M H Hassoun. A coupled gradient network approach for static and temporal mixed-integer optimization [J]. IEEE Transactions on Neural Networks, 1996, 7(3): 578-593.
- [145] M P Walsh, M E Flynn, M J Malley. Augmented Hopfield network for mixed-integer programming [J]. IEEE Transactions on Neural Networks, 1999, 10(2): 456-458.
- [146] D D Joseph, J M Mark. A Lagrangian augmented Hopfield network for mixed ingeger non-linear programming problems [J]. Neurocomputing, (2002), 42: 323-330.
- [147] M S Bazaraa, H D Sherali, C M Shetty. Nonlinear programming-theory and algorithms [M]. 2nd. New York: Wiley, 1993.
- [148] D McKay, A Stefanopoulou. Proceeding of the 2004 American control Conference, 2004: 816-821.
- [149] 杜文朝. 基于内阻测试的质子交换膜含水量软测量研究[D]. 武汉:武汉理工大学, 2009.
- [150] J Z Zhang, G D Liu, W S Yu, et al. Adaptive control of the airflow of a PEM fuel cell system [J]. Journal of Power Sources, 2008, 179: 649-659.

- [151] J W Ahn, S Y Choe. Coolant controls of a PEM fuel cell system [J]. Journal of Power Sources, 2008, 179: 252-264.
- [152] L Y Zhang, M Pan, S H Quan. Model Predictive Control of Water Management in PEMFC [J] Journal of Power Sources, 2008, 180(1): 322-329.
- [153] H I Lee, T Y Oh, S G Choi, et al. Development of 1kW class PEM fuel cell power generation system [J]. Journal of Power Sources, 2002(107): 110 -119.
- [154] Mufford W E, Langley, et al. Power control system for a fuel cell powered vehicle [P]. PatentUS5991670.
- [155] Vahidi A, Stefanpoulou A, Peng H. Model predictive control for starvation prevention in a hybrid fuel cell system [A]. Proceedings of the American Control Conference [C]. 2004, 1: 834-839.
- [156] J Golbert, D R Lewin. Model-based control of fuel cells: (1) Regulatory control [J]. Journal of Power Sources, 2004, 135(1-2): 135-151.
- [157] R Yuan, G Y Cao, X J Zhu. Predictive control of proton exchange membrane fuel cell (PEMFC) based on support vector regression machine [A]. 2005 International Conference on Machine Learning and Cybernetics[C]. 2005: 4028-4031.
- [158] J O Schumacher, P Gemmar, M Denne, et al. Control of miniature proton exchange membrane fuel cells based on fuzzy logic [J]. Journal of Power Sources, 2004, 129(2): 143-151.
- [159] P E Almeida, M G Simoes. Neural optimal control of PEM fuel cells with parametric CMAC networks [J]. IEEE Transactions on Industry Applications, 2005, 41(1): 237-245.
- [160] A Azmy, I Erlich. Online optimal management of PEM fuel cells using Neural Networks [J]. IEEE

- Transactions on Power Delivery, 2005, 20(21): 1051-1058.
- [161] F Jurado, J R Saenz. Adaptive control of a fuel cell-microturbine hybrid power plant [J]. IEEE Transaction on Energy Conversion, 2003, 18(2): 342-347.
- [162] Y P Yang, F C Wang, H P Chang, et al. Low power proton exchange membrane fuel cell system identification and adaptive control [J]. Journal of Power Sources, 2007, 164(2): 761-771.
- [163] K Sedghisigarchi, A Feliachi. Proceedings of the 35th Southeastern Symposium on System Theory, 2003: 464-467.
- [164] F C Wang, Y P Yang, H P Chang, et al. Proceedings of 4th International ASME Conference on FuelCellScience, Engineering and Technology, 2006: 6.
- [165] F C Wang, Y P Yang, C W Huang, et al. System identification and robust control of a portable proton exchange membrane full-cell system[J] Journal of Power Sources, 2007, 164(2): 704-712.
- [166] F C Wang, H T Chen, Y P Yang, et al. Multivariable robust control of a proton exchange membrane fuel cell system [J]. Journal of Power Sources, 2008, 177: 393-403.
- [167] 黄亮. 燃料电池发动机系统建模与预测控制研究[D]. 武汉: 武汉理工大学, 2009.
- [168] B Lincoln, B Bernhardsson. LQR optimization of linear system switching [J]. IEEE Transactions on Automatic Control, 2002, 47(10): 1701-1705.
- [169] X P Xu, P J Antsaklis. Optimal control of switched systems based on parameterization of the switching instants [J]. IEEE Transactions on Automatic Control, 2004, 49(1): 2-16.

- [170] S M Wei, K Uthaichana, et al. Applications of numerical optimal control to nonlinear hybrid systems [J]. Nonlinear Analysis: Hybrid Systems, 2007, 1(2): 264-279.
- [171] Pascal Grieder, Michal Kvasnica, Mato Baotic, et al. Low Complexity Control of Piecewise Affine Systems with Stability Guarantee [c]. Proceeding of the American Control Conference, 2004: 1196-1201.
- [172] C Seatzu, D Corona, A Giua, et al. Optimal Control of Continuous-Time Switched Affine Systems [J]. IEEE Transactions on Automatic Control, 2006, 51(5): 726-741.

符号及下标说明

符号:

A	电池有效面积或散热器传热面积 (cm^2)
c	水浓度
M	质量 (kg)
N	摩尔流量 (mol/s)
H	焓 (J) 或亨利常数 ($\text{Pa} \cdot \text{m}^3/\text{mol}$)
W	质量流量 (kg/s)
P	压力 (kPa)
M	摩尔质量 (kg/mol)
T	温度 (K)
t	厚度 (cm)
ϕ	相对湿度
Ω	湿度率
I	电流 (A)
R	气体常数 [$\text{J}/(\text{kg} \cdot \text{K})$] 或电阻 (Ω)
i	电流密度 (A/cm^2)
V	体积 (m^3) 或电压 (V)
n	电堆中单电池个数
J	穿过膜的水流量、转动惯量或目标函数
E	电动势或电压 (V)
F	费南德常数
ω	转速或神经网络的权值
λ	过量系数

x	状态变量
y	输出变量
u	控制变量
σ	传导率
λ	含水量
τ	力矩
n_d	电迁移系数
D_w	浓差扩散系数
Q	能量或电能
C_p	平均比热容

下标:

H_2	氢气
O_2	氧气
N_2	氮气
w	水
in	进堆
out	出堆
an	阳极
ca	阴极
rm	电堆中集总的回流管腔
st	电堆
sat	饱和
fc	燃料电池
gen	生成

mbr, m	质子交换膜
v	水蒸气
atm	大气
act	活化
ohm	欧姆
conc	浓度差
cons	冷凝
inj	加湿
l	液态
theo	理论上
elec	电力
cool	冷却
r	参考轨迹